

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO

Aprender com o Passado: Apoio à Negociação Automática nos Centros de Controlo Operacionais

José Pedro Sobreiro Furtado da Silva



Mestrado Integrado em Engenharia Informática e Computação

Orientador: Professor Doutor Eugénio Oliveira

Co-orientador: Professora Doutora Ana Paula Rocha

Supervisor TAP Portugal: António Castro

17 de junho de 2013

Aprender com o Passado: Apoio à Negociação Automática nos Centros de Controlo Operacionais

José Pedro Sobreiro Furtado da Silva

Mestrado Integrado em Engenharia Informática e Computação

Aprovado em provas públicas pelo Júri:

Presidente: Henrique Daniel de Avelar Lopes Cardoso

Arguente: Daniel Castro Silva

Vogal: Eugénio da Costa Oliveira

17 de junho de 2013

Resumo

O processo de planeamento e escalonamento dos voos de uma companhia aérea é composto por várias fases, algumas das quais começam a ser preparadas com vários meses de antecedência. Contudo, é tão importante ter um planeamento ótimo quanto conseguir mantê-lo. Esta é uma tarefa bastante complexa devido a eventos inesperados (roturas) que ocorrem perto da data da operação. Tais problemas originam quebras no planeamento que podem levar a atrasos e/ou cancelamento de voos, se nada for feito para o prevenir.

No Laboratório de Inteligência Artificial e Ciência da Computação (LIACC) está a ser desenvolvido um projeto, denominado MASDIMA (*Multi-Agent System for Disruption Management*), em colaboração com a TAP Portugal. Este projeto trata o problema da gestão de roturas implementando um sistema multiagente, que usa negociação automática na resolução distribuída de problemas em ambientes cooperativos, aplicado ao cenário de Controlo Operacional das Companhias Aéreas.

O objetivo desta dissertação é o de incorporar no sistema MASDIMA uma camada de *software* suplementar, no conjunto de agentes responsáveis pela geração, análise e decisão de novas soluções, para que este sistema possa aprender com o passado. É assim estudada a possibilidade de o sistema gerar novas soluções para os problemas atuais com base no seu conhecimento de situações similares ocorridas anteriormente.

Para que esta implementação seja uma realidade, foi criada uma nova metodologia denominada *Case-based Reasoning Distribuído em Ambientes Dinâmicos* (CBR-DDE), baseada na metodologia *Case-based Reasoning* (CBR), introduzindo desta forma a aprendizagem com o passado no apoio à negociação automática nos Centros de Controlo Operacionais.

Na presente dissertação analisa-se o impacto do uso deste tipo de aprendizagem nos seguintes aspetos: manutenção da utilidade das soluções obtidas; diminuição do tempo médio de resposta a um novo problema e aumento do nível de confiabilidade do sistema.

Através da utilização de métricas, como o tempo médio de resposta a um novo caso e a utilidade das soluções propostas, os resultados obtidos com a metodologia CBR-DDE são comparados com os resultados obtidos pelos operadores humanos do Centro de Controlo Operacional da TAP Portugal e os obtidos pelas abordagens pré-existentes no MASDIMA. Conclui-se que os objetivos deste trabalho foram atingidos.

Abstract

The process of planning and scheduling the flights of an airline consists of several steps, some of which are prepared several months in advance. Even though, having a great plan is as important as keeping it, this task can be quite demanding due to unexpected events (disruptions) that can occur close to the operation date. Such problems can lead to delays and/or cancellation of flights, if nothing is done to prevent it.

In the Laboratório de Inteligência Artificial e Ciência da Computação (LIACC) is being developed a project called MASDIMA (Multi-Agent System for Disruption Management), in collaboration with TAP Portugal. This project addresses the problem of managing disruptions by implementing a multi-agent system that uses automatic negotiation to solve problems on cooperative distributed environments, applied to the scenario of Airlines Operation Control (AOC).

The aim of this dissertation is to incorporate in MASDIMA, an additional software layer, on the set of agents responsible by the generation, analysis and decision regarding new solutions, so they can learn from the past. Therefore, it was investigated a way of having the system solve current problems based on its knowledge of similar situations occurred in the past.

In order for this to become a reality we created a new methodology called *Case-based Reasoning - Distributed for Dynamic Environments* (CBR-DDE), based on *Case-based Reasoning* (CBR). Using this methodology we are able to resolve problems, learning from the past, on the AOC.

Using metrics such as the average response time of the system to a new case and the quality of the proposed solutions, the results obtained with CBR-DDE methodology are compared with those obtained by human operators on TAP Portugal Operational Control Center and the pre-existing MASDIMA approaches. We conclude that the objectives of this work were achieved.

Agradecimentos

Este trabalho não seria possível sem a contribuição de muitas pessoas, que ao longo destes meses, ajudaram a que fosse possível tornar em realidade esta dissertação. É sempre complicado reconhecer todas as pessoas que, direta ou indiretamente, tiveram impacto neste trabalho, e a quem eu peço desde já desculpa se, neste momento, não fui capaz de me aperceber da sua contribuição.

Em primeiro lugar, quero agradecer à minha família, em especial aos meus pais e irmã, pelo carinho e paciência que tiveram para me ouvir, pelas vezes que me substituíram nas minhas responsabilidades para que eu pudesse trabalhar sem estar preocupado com mais nada, exceto a tarefa que tinha em mãos.

Aos Professores Eugénio Oliveira e Ana Paula Rocha, pelo apoio, supervisão e orientação durante a dissertação, e durante estes últimos anos. A sua dedicação, gosto e conhecimento pela área da Inteligência Artificial são um exemplo para todos nós. Sem a sua intervenção nunca teria decidido fazer a minha dissertação nesta área e, por isso, o meu muito obrigado a ambos.

Ao Engenheiro António Castro, agradeço profundamente o tempo e atenção que me dispensou ao longo de todo este trabalho. O António encarna, na minha opinião, o exemplo de que as empresas e a academia podem percorrer o caminho da ciência, em conjunto, com sucesso. O seu conhecimento e trabalho na área da gestão de roturas nos Centros de Controlo Operacional é a base todo o trabalho aqui realizado.

À colega Francisca, pelos conhecimentos sobre o MASDIMA que me transmitiu, e pela disponibilidade em trocar ideias e opiniões. Foi sem dúvida uma fonte de ajuda, disponível em qualquer instante, que me permitiu rapidamente começar o desenvolvimento deste trabalho.

A todos os meus colegas, em especial ao Pedro Simeão, pela amizade e desafios que conseguimos alcançar em conjunto ao longo deste anos de curso.

À TAP Portugal, pelos dados fornecidos para as experiências a realizar, e pela visita que fizemos às suas instalações. Ao LIACC, pelo espaço e material disponibilizado para a realização deste trabalho.

Um agradecimento especial à equipa do IEEE Universidade do Porto Student Branch (NuIEEE) que tive o prazer, e a honra, de liderar neste último ano. Pelas horas que passamos juntos, pelos almoços e jantares que fizemos e pelos objetivos que conseguimos alcançar, vós sois, sem dúvida muito especiais e não há palavras para descrever o apreço que sinto. Sem o vosso apoio, trabalho e dedicação não teria sido possível acumular o cargo de Presidente do núcleo com o trabalho desta dissertação.

Aos meus colegas da Banda Musical de Caldas das Taipas, pelos concertos que fizemos juntos e que me permitiram conjugar o trabalho com a música, o meu obrigado.

A todos os Professores com quem tive o privilégio de interagir ao longo do meu percurso académico, pelos conhecimentos e sapiência que me transmitiram.

Por fim, não posso deixar de agradecer a todos as pessoas com quem tive o prazer de me cruzar ao longo destes anos. Acredito que somos a soma das experiências que vivemos e das pessoas que

conhecemos, e por isso o meu muito obrigado por tudo aquilo que fizeram por mim, e que me permitiu chegar até aqui.

José Pedro Silva

“Conformar-se é submeter-se e vencer é conformar-se, ser vencido. Por isso toda a vitória é uma grosseria. Os vencedores perdem sempre todas as qualidades de desalento com o presente que os levaram à luta que lhes deu a vitória. Ficam satisfeitos, e satisfeito só pode estar aquele que se conforma, que não tem a mentalidade do vencedor. Vence só quem nunca consegue.”

Fernando Pessoa

Conteúdo

1	Introdução	1
1.1	Contextualização	1
1.1.1	Definição do Problema	1
1.1.2	Sistemas Multiagente	2
1.2	Objetivos	3
1.3	Contribuições Científicas	3
1.4	Estrutura da Dissertação	4
2	Estado da Arte	5
2.1	Case-based Reasoning: Fundamentação	5
2.1.1	Génese	6
2.1.2	Representação	8
2.1.3	Pesquisa e Recuperação	9
2.1.4	Reutilização e Revisão	9
2.1.5	Retenção	10
2.2	Case-based Reasoning: Aplicações Comerciais	11
2.3	Resumo	12
3	Protótipo Existente	13
3.1	Sistema MASDIMA	13
3.2	Abordagens	15
3.2.1	TSA	16
3.2.2	FB10	16
3.2.3	Q10-Min	16
3.2.4	Q10-Best	17
3.2.5	Q10-Best-Filter	17
3.2.6	Q20-Best	17
3.2.7	S10-Best	17
3.2.8	S10-Best-Filter	17
3.2.9	S20-Best	17
3.2.10	Q10-Best-V2	17
3.2.11	Q20-Best-V2	18
3.3	Limitações	18
3.4	Resumo	18
4	Conceção e Implementação	21
4.1	Descrição do Problema	21
4.1.1	Problema	21

CONTEÚDO

4.1.2	Função de Similitude	25
4.1.3	Solução	25
4.2	Metodologias Aplicadas	26
4.2.1	Base de Conhecimento	27
4.2.2	Recuperação	28
4.2.3	Reutilização e Adaptação	29
4.2.4	Retenção	30
4.3	Case-based Reasoning Distribuído em Ambientes Dinâmicos	32
4.4	Resumo	35
5	Experiências e Avaliação	37
5.1	Cenário	37
5.1.1	Métricas	41
5.1.2	Abordagens	45
5.2	Análise de Resultados	49
5.3	Resumo	64
6	Conclusão	65
6.1	Visão Geral	65
6.2	Verificação dos Objetivos	66
6.3	Contribuições Científicas	67
6.4	Limitações e Trabalho Futuro	67
A	MASDIMA	69
B	Métricas	71
B.1	Transporte Aéreo	71
B.2	Desempenho Negocial	76
B.3	Desempenho do Protocolo	79
C	Ficheiro configuração Módulo CBR	81
	Referências	85

Lista de Figuras

2.1	O ciclo CBR (adaptado)(Aamodt e Plaza, 1994)	6
2.2	Relação entre o espaço de problemas e soluções (adaptado) (De Mantaras et al., 2005)	10
3.1	Arquitetura MASDIMA (adaptado)(Castro et al., 2012)	14
4.1	Diagrama de classes UML para armazenamento de eventos	27
4.2	Diagrama de classes UML para armazenamento de soluções	28
4.3	Função $g(\Delta t)$ (4.2), $a = 1, b = e, \lambda = 1$	29
4.4	Função $j(\Delta t)$ (4.3), $\lambda' = 365$	29
4.5	Ciclo CBR-DDE	31
4.6	Diagrama de Sequência UML - CBR-DDE MASDIMA	34
5.1	Rácio Médio de Recuperação de Atrasos à Partida dos Voos (\overline{FDrcv})	54
5.2	Custo Médio com Passageiros (\overline{PC})	54
5.3	Custo Médio com Tripulação (\overline{CC})	55
5.4	Utilidades dos Agentes e $\Delta(\text{optimal})$	55
5.5	Média de Bem-estar Social (\overline{Usw})	56
5.6	Número de Casos onde as Abordagens CBR-DDE são superiores por Métrica Desempenho Negocial	58
5.7	Utilidade Média do Agente Tripulação (\overline{Ucrew}) por Causa de Evento	59
5.8	Porcentagem de (possível) Redução de Custo	60
5.9	Possível redução de custos para a TAP Portugal	60
5.10	Utilidade Média Agente Supervisor (\overline{Usup}) em função da Similitude do caso mais semelhante	61
5.11	Número Médio de Mensagens por Problema (\overline{Mpbr})	62
5.12	Número Médio de Rondas por Problema (\overline{NR})	63
5.13	Tempo por Abordagem	63
A.1	Interface do sistema MASDIMA	69

LISTA DE FIGURAS

Lista de Tabelas

4.1	Variáveis de um evento no sistema MASDIMA	22
4.2	Tipos de Causas de Eventos	23
4.3	Variáveis mais relevantes para cada causa de evento	24
4.4	Ações possíveis para a dimensão Avião	25
4.5	Ações possíveis para a dimensão Tripulação	26
4.6	Ações possíveis para a dimensão Passageiros	26
5.1	Distribuição mensal, em percentagem, dos atrasos na TAP Portugal entre Abril 2009 e Abril 2010	38
5.2	Informação disponível no ambiente de teste utilizado	38
5.3	Estrutura e informação disponível na base de conhecimento	39
5.4	Caracterização da informação do plano operacional de setembro de 2009	39
5.5	Caracterização dos problemas a resolver	40
5.6	Caracterização dos eventos utilizados para construção da Base de Conhecimento	41
5.7	Equações e parâmetros utilizados nas novas abordagens	46
5.7	Equações e parâmetros utilizados nas novas abordagens	47
5.7	Equações e parâmetros utilizados nas novas abordagens	48
5.8	Equações e parâmetros utilizados nas abordagens já existentes	48
5.9	Pesos e parâmetros para as funções de utilidades dos agentes (equações 3.4, 3.1, 3.2 e 3.3)	49
5.10	Resultados das abordagens TAP-AOC, TSA, Q10-Best-V2 e Q20-Best-V2	50
5.11	Resultados das abordagens CBR10-Met-01, CBR10-Met-02 e CBR10-Met-03	51
5.12	Resultados das abordagens CBR20-Met-01, CBR20-Met-02 e CBR20-Met-03	52

LISTA DE TABELAS

Abreviaturas e Símbolos

API	Application Programming Interface
AOC	Airline Operation Control
AOCC	Airline Operational Control Center
CCO	Centro de Controlo Operacional
CBR	Case-based Reasoning
CBR-DDE	Case-based Reasoning - Distributed for Dynamic Environments
GQN	Generic Q-Negotiation
IATA	International Air Transport Association
IE	Information Entity
LIACC	Laboratório de Inteligência Artificial e Ciência da Computação
MASDIMA	Multi-Agent System for Disruption Management
SARSA	State-Action-Reward-State-Action
SMA	Sistema Multiagente
TSA	Traditional Sequential Approach
UML	Unified Modeling Language

Capítulo 1

Introdução

Este capítulo pretende apresentar o objeto de estudo desta dissertação. Após uma breve exposição do contexto e motivação da dissertação, são descritos os objetivos e contribuições científicas que nos propusemos atingir neste trabalho. Por último, é apresentada a estrutura do documento.

1.1 Contextualização

Esta dissertação enquadra-se no âmbito do projeto MASDIMA, desenvolvido no Laboratório de Inteligência Artificial e Ciência da Computação (LIACC), sediado na Faculdade de Engenharia da Universidade do Porto, em colaboração com a TAP Portugal, sobre negociação automática na Resolução de Problemas Distribuídos em Ambientes Cooperativos, aplicado ao Controlo Operacional das Companhias Aéreas. O projeto MASDIMA trata da gestão de roturas usando um sistema multiagente na sua implementação.

1.1.1 Definição do Problema

O controlo das operações aéreas é uma importante e complicada tarefa que as companhias aéreas têm que levar a cabo diariamente. Mesmo para companhias aéreas de pequena dimensão, como a TAP Portugal, este é um problema complexo. O escalonamento operacional ótimo, que resulta da aplicação de técnicas de otimização, tem uma grande probabilidade de ser afetado, causando, por exemplo, o atraso de voos. Se nada for feito para gerir esta rotura, o atraso pode ser propagado para outros voos, aumentando a complexidade da situação.

O processo de escalonamento de uma companhia aérea contém várias fases, algumas das quais começam a ser preparadas com vários meses de antecedência. Contudo, é tão importante ter um planeamento ótimo quanto conseguir mantê-lo. Esta é uma tarefa bastante complicada devido à ocorrência de eventos inesperados que surgem próximo da data da operação. Estes problemas originam quebras no planeamento que podem levar a atrasos e/ou cancelamento de voos, caso nada seja feito para o prevenir (Teixeira et al., 2013).

Há várias causas que podem levar ao não cumprimento do planeado. De acordo com CODA Digest (2012), a *International Air Transport Association* (IATA) definiu diferentes causas que

podem originar eventos que levem a roturas. As principais causas identificadas são de dois tipos: (i) reacionárias, que resultam de propagação de atrasos; (ii) técnicas, resultantes da gestão do tráfego aéreo, de passageiros e climatéricas. Estas anomalias podem ter origem em problemas técnicos com os aviões, em problemas relacionados com a tripulação, e/ou em problemas com passageiros. Qualquer anomalia pode causar entropia no sistema aéreo internacional, o que torna a gestão de roturas uma tarefa complexa e crítica.

Para solucionar estas anomalias, as companhias aéreas, geralmente, têm Centros de Controlo Operacional (CCO ou AOCC¹). Existem vários tipos de arquiteturas para os CCO, sendo as organizações mais comuns os Centros de Decisão, os Centros Integrados ou os *Hub Control Center* (Castro, 2008). Independentemente do tipo de organização usada, os papéis de Supervisor, manager Avião, manager Tripulação e manager Passageiro, entre outros, são comuns a todos os tipos de organização (Kohl et al., 2007).

As estatísticas apresentadas em CODA Digest (2012) mostram que estes problemas, apesar de não esperados, são muito frequentes. Em termos de custos, os mesmos autores estimam que cada minuto de atraso custou, em 2011, cerca de setenta e dois euros, incluindo custos diretos e indiretos. Assim, é de extrema importância que uma companhia aérea seja capaz de reagir, em tempo útil, a estas alterações, precisando para isso de fazer uma gestão de roturas² (Castro e Oliveira, 2011).

A solução proposta em Castro e Oliveira (2011) é um sistema multiagente (SMA) denominado MASDIMA capaz de detetar problemas, analisar quais os recursos afetados e de propor uma solução, respeitando as restrições do ambiente. Esta dissertação tem como objetivo introduzir aprendizagem com o passado, nos Centros de Controlo Operacional, apoiando a negociação automática já hoje implementada no protótipo MASDIMA.

1.1.2 Sistemas Multiagente

O sistema MASDIMA, a usar no decorrer do trabalho desta dissertação, é um sistema multiagente, como já referido.

Um sistema multiagente é um sistema que inclui um ou mais agentes. Por agente entende-se uma entidade computacional que goza das seguintes propriedades (Wooldridge e Ciancarini, 2001):

- *autonomia*: os agentes podem ter um estado, que não é acessível por outros, e tomar decisões baseadas nesse estado, sem intervenção direta de humanos ou outros agentes;
- *reatividade*: os agentes encontram-se num ambiente (físico ou não), são capazes de interpretar esse ambiente e responder, em tempo útil, às alterações que nele ocorrem;
- *proatividade*: os agentes não agem simplesmente em resposta a alterações do ambiente, podendo tomar a iniciativa de agir se o considerarem oportuno;

¹do inglês: *Airline Operations Control Center*

²processo de minimizar o atraso e o custo de voos

- *sociabilidade*: os agentes podem interagir com outros agentes (ou humanos) através de protocolos de comunicação. Tipicamente têm capacidade para se comprometerem com atividades sociais, como a resolução cooperativa de problemas ou negociação, de forma a atingirem os seus objetivos.

As propriedades supracitadas, bem com a escalabilidade, modularidade e a descentralização, características dos sistemas multiagente, tornam este paradigma indicado na modelação dos Centros de Controlo Operacional das Companhias Aéreas (Castro et al., 2012).

1.2 Objetivos

Com esta dissertação pretende-se estudar a possibilidade de obter soluções diminuindo o tempo de resposta médio do sistema MASDIMA a um novo problema de rotura, aumentando o seu grau de confiabilidade, mantendo, simultaneamente, o nível de qualidade das soluções apresentadas.

Por sistema confiável entende-se um sistema capaz de fornecer soluções que, à primeira vista, possam passar como soluções desenvolvidas por operadores humanos, isto é, um sistema com elevado grau de confiabilidade é um sistema cujos responsáveis por supervisionar o seu funcionamento sentem que produz soluções com as quais se reveem. A qualidade das soluções será medida através da utilidade relativa que cada agente lhes atribui.

A concretização destes objetivos será analisada através da utilização de métricas como o tempo médio de resposta do sistema a um novo caso, e a determinação da qualidade das soluções propostas, em comparação com as soluções dadas pelo Centro de Controlo Operacional (CCO) da TAP Portugal, e com as produzidas pelas abordagens pré-existentes no sistema MASDIMA.

1.3 Contribuições Científicas

As contribuições científicas mais importantes, presentes nesta dissertação, resumem-se nos pontos seguintes:

- Inclusão de *Case-based Reasoning*³ (CBR) como técnica de resolução de problemas na gestão de roturas nos Centros de Controlo Operacional de Companhias Aéreas;
- Abordagem distribuída da metodologia CBR, através da cooperação entre agentes;
- Criação de um novo método, baseado em CBR, denominado CBR-DDE, que permita a reutilização e adaptação de soluções em sistemas que trabalham sobre ambientes dinâmicos;
- Definição de um método de comparação de roturas nos planos operacionais das companhias aéreas, que permita aferir a sua semelhança;

³uma tradução possível seria Raciocínio Baseado em Casos no entanto, dado se tratar de uma terminologia muito divulgada, no seio da comunidade científica, decidimos mantê-la.

1.4 Estrutura da Dissertação

Para além da introdução, esta dissertação inclui mais 5 capítulos:

- **Capítulo 2 - Estado da Arte:** Contém a revisão bibliográfica de paradigmas e metodologias utilizadas neste trabalho de dissertação. Começamos por abordar os aspetos chave da metodologia *Case-based Reasoning*, desde a sua génese às várias etapas que a compõem, e analisamos, sucintamente, alguns exemplos da sua aplicação em sistemas comerciais. Esta informação é ponto de partida para a conceção e implementação explanadas no capítulo 4, e permitirá analisar os resultados obtidos no capítulo 5.
- **Capítulo 3 - Análise do Protótipo Existente:** Este capítulo contém a exploração do protótipo MASDIMA, incluindo uma análise da sua estrutura, das abordagens de resolução de problemas já implementadas, e das limitações que levaram ao trabalho desta dissertação.
- **Capítulo 4 - Conceção e Implementação:** Este capítulo descreve a solução estudada e implementada neste trabalho. Inicia-se pela formalização dos conceitos de problema e solução no âmbito do sistema MASDIMA, conceptualizando-se a noção de caso neste contexto. É efetuada a definição da função de similitude que permitirá determinar o grau de semelhança entre casos, seguindo-se uma apresentação das metodologias a aplicar em cada uma das etapas do ciclo CBR. Por fim, o resultado das propostas feitas ao longo do capítulo, é identificada uma nova metodologia, baseado em CBR, e que vem eliminar alguns dos entraves da utilização da metodologia CBR em sistemas distribuídos e que trabalham sobre ambientes dinâmicos.
- **Capítulo 5 - Experiências e Avaliação:** Este capítulo contém a descrição do cenário utilizado para validar a metodologia proposta, e sua implementação no sistema MASDIMA. São apresentados os resultados das experiências efetuadas e feita uma discussão sobre os mesmos.
- **Capítulo 6 - Conclusão:** Neste capítulo, descrevemos sumariamente o trabalho e os principais desenvolvimentos produzidos nesta dissertação. Apresentamos possíveis linhas de ação a percorrer no futuro, no sentido de dar continuidade ao trabalho agora iniciado.

Capítulo 2

Estado da Arte

Neste capítulo é efetuada uma revisão bibliográfica abordando os aspetos chave para a concretização do trabalho desta dissertação. Nas secções iniciais será analisado o estado da arte relativo à metodologia *Case-based Reasoning*, apresentando-se as aplicações comerciais mais relevantes que fazem uso desta metodologia.

2.1 Case-based Reasoning: Fundamentação

Case-based Reasoning (CBR) é uma abordagem para a resolução de problemas que enfatiza a importância da experiência prévia. Os novos problemas são resolvidos através da reutilização e, se necessário, adaptação de soluções de problemas similares que foram resolvidos no passado (De Mantaras et al., 2005). Ou seja, é uma técnica que permite a resolução de um novo problema através da memória sobre situações similares passadas, reutilizando informação e conhecimento dessa situação (Aamodt e Plaza, 1994). Este procedimento pode ser observado na figura 2.1, onde se descreve um ciclo CBR.

Em Aamodt e Plaza (1994), os autores referem que CBR é uma metodologia onde o raciocínio é baseado em casos, mas nada nos é dito sobre como é que realmente funciona. CBR é uma metodologia para a resolução de problemas mas não prescreve nenhuma tecnologia em específico (Watson, 1999).

Resolver um problema utilizando CBR envolve:

- (i) obter uma descrição do problema;
- (ii) criar um caso com base nessa informação;
- (iii) medir a similitude entre o caso atual e os anteriores previamente guardados;
- (iv) pesquisar e recuperar o(s) caso(s) mais semelhante(s);
- (v) tentar reutilizar a solução encontrada para esses problemas resolvidos no passado;
- (vi) adaptar a solução recuperada, se necessário;

(vii) reter o novo caso, expandindo a base de conhecimento.




Figura 2.1: O ciclo CBR (adaptado)(Aamodt e Plaza, 1994)

Segue-se, nesta secção, uma revisão da literatura sobre as diferentes etapas de um ciclo CBR, nomeadamente a génese (secção 2.1.1), representação (secção 2.1.2), pesquisa e recuperação (secção 2.1.3), reutilização e revisão (secção 2.1.4) e retenção (secção 2.1.5) em CBR.

2.1.1 Génese

As raízes da metodologia CBR, na Inteligência Artificial, encontram-se nos trabalhos de Schank sobre a memória dinâmica, onde é dado um papel central à recordação de situações (casos) passadas para a resolução de problemas (Schank, 1983). Do ponto de vista geográfico, o conceito começou por ser aplicado em diversos trabalhos nos Estados Unidos da América, sendo que apenas mais tarde foi trazido para a Europa, já fortemente ligado aos sistemas periciais.

Case-based Reasoning tem as suas raízes em quatro disciplinas distintas: ciência cognitiva, representação e inferência sobre o conhecimento, *machine learning* e matemática. Todas estas áreas, heterogêneas e com as suas próprias raízes e fundamentos, fazem com que CBR seja uma interseção complexa destes elementos, sendo difícil ter uma visão global (Richter e Aamodt, 2005). A influência de cada uma destas quatro disciplinas, na metodologia CBR, é brevemente explanada nos parágrafos seguintes.

Ciência Cognitiva

A maior influência da ciência cognitiva na metodologia CBR centra-se essencialmente nos termos *experiência*, *memória* e *analogia*. O modelo, proposto por Schank em 1983, sobre a teoria da memória dinâmica, tem uma forte componente psicológica, derivada daquilo que foi cogitado por Bartlett (1932). Este trabalho acabou mais tarde por ser posto em prática no sistema *Cyrus* (Kolodner, 1983a). Podemos dizer que CBR é um raciocínio analógico, que opera dentro de um único domínio, ignorando o facto deste tipo de inferência abarcar, muitas vezes, conhecimentos de várias áreas.

Representação e Inferência sobre o Conhecimento

Na metodologia CBR um conjunto de casos representa conhecimento de primeiro grau, sobre o qual são utilizados métodos de inferência aos novos casos para determinar semelhanças, fazer adaptações e aprender.

Foram efetuadas várias tentativas para criar novos formalismos lógicos e cálculos para CBR (Díaz-Agudo e González-Calero, 2001; Plaza, 1995). Todavia, os requisitos particulares do CBR são normalmente tratados à medida que surgem, sendo que são raros os casos onde se podem aplicar formalismos genéricos.

O conceito de *knowledge containers* trouxe nova luz sobre a matéria, tornando possível a entrada de casos sem que os compreendamos verdadeiramente (Richter, 2003). Os *knowledge containers* são o vocabulário, a medida de similitude, a base de conhecimento e as regras de adaptação. O aspeto fundamental é que o conhecimento pode ser deslocado entre *knowledge containers* de acordo com o processo de aprendizagem.

Um ponto fulcral da representação do conhecimento é a forma de indexar um conjunto de casos com significado, de maneira eficiente do ponto de vista da estrutura de memória, enquadrando, de forma equilibrada, a plausibilidade cognitiva e a eficiência computacional. As estruturas mais usadas em CBR são as mesmas das tecnologias de bases de dados (por exemplo tabelas relacionais), sendo que também podem ser utilizadas outras estruturas, como árvores de decisão, árvores discriminatórias ou árvores *k-d* (Richter e Aamodt, 2005).

Machine Learning

A metodologia CBR, apesar de não poder ser encarada como uma área de estudo de *machine learning*, tem uma relação estreita com esta. O ciclo CBR (figura 2.1) pode considerar-se uma aproximação de *machine learning* apelidada de *lazy learning* (Richter e Aamodt, 2005).

Lazy learning caracteriza-se por ser uma aprendizagem diferida, dependente dos novos casos que chegarem ao sistema. Face à aprendizagem *eager learning*, *lazy learning* tem como principal vantagem a possibilidade de resolver múltiplos problemas em simultâneo, todavia requer algum espaço para armazenar os conjuntos de teste.

2.1.2 Representação

De forma a conseguir aprender com o passado, é necessário encontrar uma representação de casos que, na medida do possível, nos permita a extração e análise de conhecimento, do domínio e do contexto, para que seja possível inferir uma nova solução, quando na presença de um novo caso. A experiência que um novo caso traz pode ser estruturada de várias formas, sendo muito comumente subdividida na descrição do problema e descrição da solução (Bergmann et al., 2005).

Em Kolodner (1991) recomenda-se que um caso contenha: a descrição do problema; a solução proposta (podendo incluir informação sobre como foi atingida); o resultado obtido; o estado do mundo após a execução da solução proposta; e, quão perto foi o comportamento da solução do esperado.

A representação de um caso em CBR faz uso das formas tradicionais de representação da Inteligência Artificial, de maneira a que a representação da experiência possibilite o raciocínio sobre ela (Bergmann et al., 2005). Muitos formalismos foram propostos, sendo que os três tipos mais utilizados são: *feature vector*, ou proposicional; *case structured*, ou relacional; *textual*, ou semiestruturado.

Foram ainda propostos outros tipos de representação mais avançados, mas que provêm dos conceitos referidos anteriormente, baseando-se em variações e/ou conjugação de técnicas (Kolodner, 1983b; Bergmann e Wilke, 1996; Zito-Wolf, 1993).

Feature Vector

Nas abordagens através de *feature vector*, os casos são guardados como vetores de pares atributo-valor, similares às representações utilizadas em *machine learning* (2.1.1). Esta abordagem é normalmente utilizada em domínios pouco definidos, isto é, quando não é conhecido com precisão qual o tipo de dados e que atributos são necessários armazenar para cada caso.

Case Structured

Esta forma de representação tem origem na noção episódica de caso, sendo normalmente construída em volta de um formalismo baseado em *frames*. Como os *frames* podem ser vistos como um subconjunto de lógica de primeira ordem, este tipo de representação é um exemplo daquilo que em *machine learning* se denomina de representações relacionais. Os casos, nesta perspectiva, são conjuntos de relações entre objetos.

Se encaramos um caso como uma condição, utilizando uma perspectiva estruturada dos casos como termos de uma função, ganhamos um maior conhecimento sobre vários aspetos do CBR (Plaza, 1995). Através da noção de que um subtermo é também ele um termo, podemos integrar conhecimento do domínio, por via de uma hierarquia de classificação e de um conjunto de casos compostos, que poderá originar lógicas de ordem n .

Textual

A representação textual, ou semiestruturada, impõe uma estruturação fraca dos casos, indo no sentido oposto ao da representação estruturada. Isto faz com que as experiências possam ser capturadas em documentos, sendo normalmente representadas como conjuntos de itens linguísticos, permitindo a introdução de mais semântica, para uma melhor interpretação e reutilização de um caso.

A representação de casos textuais pode ser atingida através da decomposição do texto que constitui um caso em *information entities*, entidades informacionais (IE) (Lenz e Burkhard, 1996). Uma IE é uma palavra, ou frase, contida num texto que é relevante para definir a possibilidade de reutilização de um episódio capturado num caso.

2.1.3 Pesquisa e Recuperação

Estando os dados, ou casos, corretamente representados, surge a necessidade de os pesquisar, recuperando aqueles que se apresentam como similares ao problema que queremos resolver.

A definição da similitude entre dois casos é uma questão que tem sido alvo de grande investigação (De Mantaras et al., 2005; Kolodner, 1983b; Stanfill e Waltz, 1986) e, dependendo da forma como a representação é feita, esta tarefa pode exigir muitos recursos de computação, o que dificulta a obtenção de uma resposta em tempo real.

Uma das abordagens possíveis, para a obtenção do caso mais semelhante, é a comparação do problema a resolver com todos os casos guardados. Através desta comparação é atribuída uma medida de similitude para com todos os casos na base de conhecimento. Isto apresenta uma complexidade $O(n)$, sendo n o número de casos na base de conhecimento e, se n for um valor muito elevado, esta pode não ser uma abordagem aceitável. O algoritmo *k-nearest neighbor* é um exemplo de uma estratégia por vezes utilizada na determinação do caso mais semelhante (Keller et al., 1985).

Existem outras abordagens que, com base no mesmo princípio, tentam resolver este problema. Uma delas é a proposta de Wess et al. (1994) onde se agrupam casos similares entre si numa árvore binária *k-dimensional*. Desta forma, ao iniciar a pesquisa por casos semelhantes, podemos desde logo desconsiderar alguns deles, diminuindo o número de casos para os quais teremos que calcular o valor de similitude. Na figura 2.2 podemos ver que à medida que a distância entre dois casos (R) aumenta, a distância entre a solução do caso mais semelhante e a nova solução gerada por adaptação (A) também aumenta.

2.1.4 Reutilização e Revisão

O processo de reutilização no ciclo da metodologia CBR é responsável por propor uma solução para um novo problema, partindo das soluções presentes nos casos recuperados. Reutilizar um caso pode ser tão simples quanto retornar a solução, de um dos casos recuperados, inalterada. Isto acontece frequentemente para tarefas de classificação. Torna-se, contudo, mais complicado se existirem diferenças significativas entre o novo caso e o caso recuperado. Nestas situações,

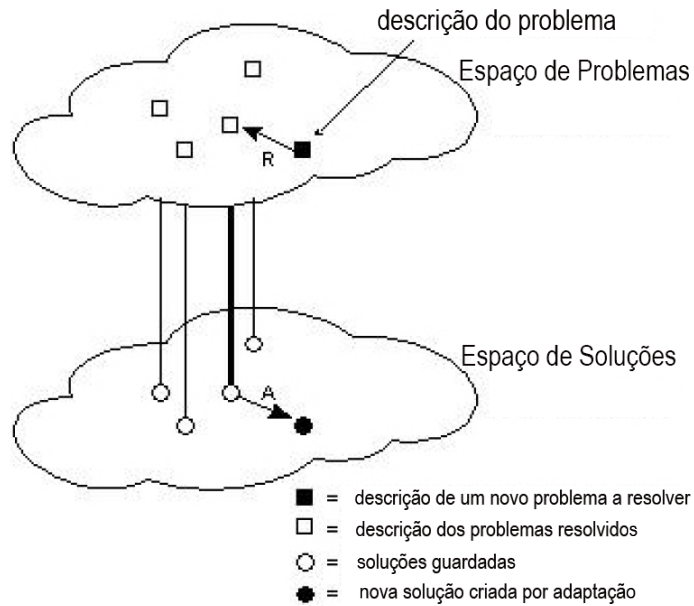


Figura 2.2: Relação entre o espaço de problemas e soluções (adaptado) (De Mantaras et al., 2005)

as soluções podem ter que ser adaptadas, de forma a ter em consideração diferenças importantes (De Mantaras et al., 2005).

A adaptação torna-se particularmente relevante quando a metodologia CBR é utilizada na resolução de problemas de forma construtiva, como, por exemplo, problemas de *design*, configuração ou planeamento (como é o caso do problema a tratar neste trabalho).

Genericamente, a complexidade dos métodos de adaptação difere em duas dimensões: o que é mudado na solução recuperada; e, como é essa mudança conseguida. A adaptação por *substituição* simplesmente substitui alguma parte, ou partes, da solução recuperada, enquanto que a adaptação por *transformação* altera a estrutura da solução (Kolodner, 1983b). Estas duas abordagens realizam a adaptação através da alteração direta da proposta de solução recuperada. Existem, no entanto, adaptações mais complexas que derivam a solução para o novo caso com base no processo de inferência que permitiu a obtenção da solução para casos passados (Bradley P. Allen, 1994).

2.1.5 Retenção

A retenção, apresentada como o último passo no ciclo CBR (figura 2.1), visa guardar o mais recente caso resolvido na base de conhecimento (Aamodt e Plaza, 1994).

Existem várias questões a ter em conta quando se pretende aprender um novo caso, e diferentes sistemas têm encontrado diferentes maneiras de efetuar essa retenção. A maioria tende a guardar a especificação do problema colocado e a solução final, quando esta foi considerada como bem sucedida. Quando o resultado não é tão fiável, ou o critério de sucesso é mais complexo, as representações dos casos devem incluir mais informações sobre o resultado da aplicação da solução (Goel e Kolodner, 1991).

Outra questão é o que guardar sobre a solução. Há sistemas que guardam apenas a solução final, enquanto que outros guardam todo o processo que permitiu chegar à solução. Uma estrutura rica em informação, isto é, que contenha mais detalhes, permitirá descrever o processo de tomada de decisão que levou à solução (Veloso e Carbonell, 1994) podendo, mais tarde, facilitar o processo de reutilização das soluções.

Em geral, a visão moderna de retenção acomoda uma perspectiva muito mais ampla do que significa, para um sistema CBR, aprender com a sua experiência de resolução de problemas. Por oposição, a visão tradicional de retenção compreende apenas a retenção do problema original e da solução, sem mais detalhes adicionais. Esta visão moderna é, em grande parte, uma resposta a questões críticas que surgiram durante a aplicação de sistemas CBR na resolução de problemas em cenários complexos.

2.2 Case-based Reasoning: Aplicações Comerciais

Apesar do enorme potencial de domínios onde o CBR tem sido explorado, as aplicações comerciais de CBR têm-se focado, na sua maioria, na pesquisa e recuperação de casos para apoio à decisão (Kolodner, 1991). Sistemas deste tipo são, norma geral, mais simples de implementar pois evitam o processo de reutilização e adaptação do ciclo CBR.

Aplicações de CBR que vão para além da pesquisa e recuperação de casos, e que incorporem reutilização e adaptação para resolução de problemas, não têm recebido tanta atenção do mundo comercial. Isto acontece porque a metodologia CBR não se tem mostrado tão efetiva quanto sistemas baseados em regras ou modelos, principalmente em situações onde a teoria, não a experiência, são o principal guia para a resolução de problemas e onde as soluções são únicas para cada situação (Bradley P. Allen, 1994). Este é precisamente o tipo de problema que nos propomos resolver.

Um exemplo de uma aplicação comercial baseada em CBR é o sistema SMART: Support Management Automated Reasoning Technology for Compaq Customer Service (Acorn e Walden, 1992). SMART foi um sistema integrado de registo de chamadas e resolução de problemas, que continha casos relacionados com o diagnóstico de falhas de produtos da Compaq, e que data de 1992. O sistema dava suporte ao centro de apoio técnico da Compaq, pesquisando o caso mais semelhante da base de casos conhecidos e apresentava essa informação ao operador, que auxiliava o cliente na resolução do seu problema.

Outro exemplo de um sistema comercial é o SQUAD (Kitano et al., 1992), um sistema para a captura e distribuição de conhecimento sobre controlo de qualidade de *software*, desenvolvido pela NEC Corporation.

Mais recentemente, em 2006, foi implementado, na GENCO Distribution System, um projeto piloto de gestão de recursos que utiliza RFID (*Radio-Frequency IDentification*). Este é um sistema baseado em CBR que incorpora a tecnologia RFID para explorar importantes atributos na pesquisa e recuperação de casos (Chow et al., 2006).

Todos estes sistemas têm em comum o facto de requererem pouca, ou nenhuma, reutilização e adaptação de casos para resolver problemas. Isto vem realçar ainda mais a dificuldade já esperada,

de que a reutilização e adaptação teórica, prevista em Aamodt e Plaza (1994), tem-se revelado, até agora, inexecutável na prática.

2.3 Resumo

Neste capítulo foi descrita a metodologia CBR, destacando o seu ciclo de vida, e enumerados alguns exemplos de aplicações comerciais que utilizam CBR.

Como estudado, a metodologia CBR estabelece um conjunto de princípios que permite a aprendizagem com o passado, de forma iterativa. É esta a metodologia que se pretende usar na implementação de um módulo adicional no sistema MASDIMA, que permita, ao conjunto de agentes responsáveis pela geração, análise e decisão de novas soluções, a aprendizagem com o passado.

Os exemplos comerciais de CBR mostram-nos que apenas as primeiras etapas do ciclo CBR (representação, pesquisa e recuperação) têm sido implementadas na prática. O que demonstra que as fases de reutilização e adaptação de soluções são um dos principais entraves à aplicação em pleno desta metodologia.

Capítulo 3

Protótipo Existente

Um dos objetivos desta dissertação é a inclusão, no sistema MASDIMA, de uma camada suplementar, no conjunto de agentes responsáveis pela geração, análise e decisão de novas soluções, para que este sistema possa aprender com o passado. Neste capítulo, vamos analisar a arquitetura do sistema MASDIMA, as abordagens já implementadas no protótipo existente e as suas atuais limitações.

3.1 Sistema MASDIMA

MASDIMA, *Multi-Agent System for Disruption Management*, é um sistema multiagente que representa as entidades existentes num Centro de Controlo Operacional tradicional de uma companhia aérea. Possui capacidade para a tomada de decisão automática e a resolução de problemas de forma inteligente na gestão de roturas. É capaz de interagir com um supervisor humano, mostrando-lhe as soluções encontradas, captando a sua opinião e mudando o seu comportamento em função desta opinião (Castro et al., 2012).

A resolução de um problema, que pode levar a uma rotura pontual do plano operacional de uma companhia aérea, tem geralmente em consideração as três dimensões que o compõem: o avião, a tripulação e os passageiros. No sistema MASDIMA estas três dimensões são modeladas através dos agentes *Manager* Avião, *Manager* Tripulação e *Manager* Passageiros e respetivos especialistas.

A arquitetura do sistema MASDIMA, que modela um Centro de Controlo Operacional de uma companhia aérea, está representada na figura 3.1. No âmbito desta dissertação, não iremos analisar todos os agentes representados nesta figura, focando-nos apenas nos mais relevantes, que são: o Supervisor e os *managers* das componentes Avião, Passageiros e Tripulação.

Atualmente, os agentes Supervisor, *Manager* Avião, *Manager* Tripulação e *Manager* Passageiros participam numa negociação automática utilizando um protocolo denominado *Generic Q-Negotiation* (GQN). A negociação GQN é utilizada como um mecanismo de decisão que permite a obtenção de uma solução integrada, isto é, uma solução que considera simultaneamente as três dimensões do problema. Esta negociação é multirronda e multiatributo, sendo os atributos em

Protótipo Existente

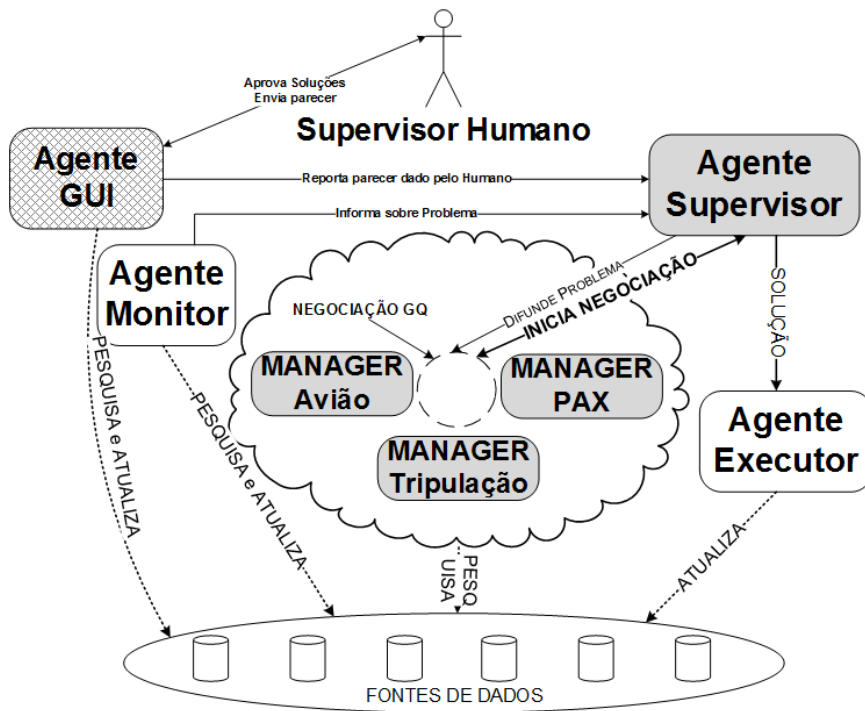


Figura 3.1: Arquitetura MASDIMA (adaptado)(Castro et al., 2012)

negociação o custo e o atraso em cada uma das dimensões. O agente Supervisor funciona como um mediador entre os agentes *manager*, recebendo uma proposta completa de cada um destes três agentes (Castro et al., 2012).

Um agente *manager* possui competência para a resolução do problema do ponto de vista da sua dimensão, pelo que disponibiliza uma solução parcial para o problema original. Um agente *manager* não encontra por si as soluções parciais da sua dimensão, mas sim os seus agentes especialistas. Quando um agente *manager* recebe um pedido por parte do Supervisor, este solicita à sua equipa de agentes especialistas a resolução do problema do ponto de vista da sua dimensão. Os agentes especialistas são responsáveis pela procura de soluções para os subproblemas relacionados com a sua própria dimensão, recorrendo a algoritmos predefinidos de resolução de problemas (Teixeira et al., 2013). Cada agente *manager* envia ao agente Supervisor uma solução completa, que é obtida através da negociação com os outros dois agentes *manager* (negociação intermanager).

Após receber as três propostas de solução do problema dos diferentes agentes *manager*, o agente Supervisor avalia-as, utilizando os seus valores preferenciais, através de uma função de utilidade própria. Cada agente *manager* é então informado se foi ou não o vencedor desta avaliação, terminando assim uma ronda de negociação. Este processo repete-se por um número fixo de rondas, definido pelo utilizador do sistema. Após atingir o número limite de rondas, o agente Supervisor escolhe a melhor solução e apresenta-a ao agente Executor.

A interface do sistema MASDIMA pode ser consultada no anexo A.

3.2 Abordagens

Entende-se por abordagem o método utilizado na resolução de um problema. O protótipo existente inclui várias abordagens usadas para teste do sistema.

Todas as abordagens aqui referidas, exceto a abordagem TSA - *Traditional Sequential Approach* (3.2.1), utilizam o protocolo GQN - *Generic Q-Negotiation* como mecanismo de decisão. A definição conceptual do mecanismo foi apresentada em Castro (2013).

Em todas as abordagens, o agente Supervisor e os agentes *manager* usam a mesma função de utilidade na avaliação das propostas recebidas. As funções de utilidade de cada um dos agentes, originalmente definidas em Castro (2013), são aqui reproduzidas nas equações 3.1, 3.2, 3.3 e 3.4.

A função de utilidade do agente *Manager* Avião é dada por:

$$U_{a/c} = 1 - \left(v_1 \left(\frac{ad}{\max(ad)} \right) + v_2 \left(\frac{ac}{\max(ac)} \right) \right) \quad (3.1)$$

onde: v_1 e v_2 representam o peso de cada um dos atributos, e têm, cada uma delas, um valor entre 0 e 1; ad é o atraso do avião e ac o custo, também, do avião. Mais detalhes sobre o cálculo do custo do avião podem ser encontrados em Castro (2013).

A função de utilidade do agente *Manager* Tripulação é dada por:

$$U_{crew} = 1 - \left(v_1 \left(\frac{cd}{\max(cd)} \right) + v_2 \left(\frac{cc}{\max(cc)} \right) \right) \quad (3.2)$$

onde: v_1 e v_2 representam o peso de cada um dos atributos, e têm, cada uma delas, um valor entre 0 e 1; cd é o atraso da tripulação e cc o custo, também, da tripulação. Mais detalhes sobre o cálculo do custo da tripulação podem ser encontrados em Castro (2013).

A função de utilidade do agente *Manager* Passageiros é dada por:

$$U_{pax} = 1 - \left(v_1 \left(\frac{pt}{\max(pt)} \right) + v_2 \left(\frac{pc}{\max(pc)} \right) \right) \quad (3.3)$$

onde: v_1 e v_2 representam o peso de cada um dos atributos, e têm, cada uma delas, um valor entre 0 e 1; pt é o tempo de viagem dos passageiros (isto é, o tempo decorrido entre a partida do primeiro voo até à chegada do último voo dos passageiros) e pc o custo dos passageiros. Mais detalhes sobre o cálculo do custo dos passageiros podem ser encontrados em Castro (2013).

A função de utilidade do agente Supervisor é dada por:

$$U_{sup} = 1 - \left[\alpha_1 \left(w_{11} \left(\frac{ad}{\max(ad)} \right) + w_{12} \left(\frac{ac}{\max(ac)} \right) \right) + \alpha_2 \left(w_{21} \left(\frac{cd}{\max(cd)} \right) + w_{22} \left(\frac{cc}{\max(cc)} \right) \right) + \alpha_3 \left(w_{31} \left(\frac{pt}{\max(pt)} \right) + w_{32} \left(\frac{pc}{\max(pc)} \right) \right) \right] \quad (3.4)$$

onde: w_{ij} representa a importância de cada atributo na dimensão ($i \in \{\text{avião, tripulação, passageiros}\}$ e $j \in \{\text{atraso, custo}\}$) e α_i a importância de cada dimensão no problema.

As diferentes abordagens consideradas atualmente são descritas nas secções seguintes.

3.2.1 TSA

Segundo Castro (2013), o atual processo de gestão de roturas no CCO segue, tipicamente, uma abordagem sequencial para a resolução do problema. Isto é, é resolvido o problema de cada uma das dimensões, de forma sequencial, começando-se, geralmente, pela dimensão avião, visto ser, à partida, aquela que apresenta menor flexibilidade. A partir da solução parcial resultante da resolução dada pela dimensão avião é gerada a solução da dimensão tripulação e, por fim, é atendida a dimensão passageiros.

3.2.2 FB10

Esta abordagem não inclui nenhum mecanismo de aprendizagem. Os agentes especialistas geram soluções candidatas usando ações (trocar um avião, utilizar um tripulante de reserva, ...) de acordo com uma determinada probabilidade, obtida através de entrevistas a operadores humanos no CCO da TAP Portugal. Durante as várias rondas de negociação, o agente Supervisor atribui *feedback* às propostas dos agentes *manager*.

Cada agente *manager* recebe dos seus agentes especialistas um número máximo de dez soluções candidatas. De ronda para ronda, algumas soluções candidatas não são repetidas, de forma a considerar a dinâmica do ambiente.

No início de cada ronda de negociação os agentes *manager* utilizam a solução com maior utilidade que respeita o *feedback* fornecido para iniciar a negociação intermanager. No final da negociação, o agente Supervisor escolhe, das propostas recebidas, aquela que tem a maior utilidade.

3.2.3 Q10-Min

Esta abordagem inclui um mecanismo de aprendizagem baseado no algoritmo Q-Learning, para a geração de propostas na negociação. A aprendizagem é utilizada pelos agentes *manager* na negociação com o agente Supervisor e também na negociação entre si (negociação intermanager). Os agentes especialistas geram soluções candidatas sem terem em consideração a probabilidade de cada ação disponível, ao contrário da abordagem anterior, isto é, todas as ações disponíveis são equiprováveis.

O agente supervisor atribui um *feedback* às propostas enviadas pelos agentes *manager* que é usado no algoritmo de aprendizagem Q-Learning (como valores do estado). Os agentes *manager*, das soluções candidatas apresentadas pelos agentes especialistas, desconsideram aquelas que não seguem a ação sugerida pelo Q-Learning. Das restantes, selecionam a solução candidata que se encontrar *mais próxima* da proposta anterior. É com esta solução candidata que a negociação entre *managers* é iniciada.

À semelhança da abordagem anterior, um número máximo de dez soluções candidatas são enviadas para cada *manager* e, de uma para outra ronda, algumas das soluções candidatas não são repetidas, de forma a que a dinâmica da informação seja tida em conta.

3.2.4 Q10-Best

Esta abordagem é semelhante à abordagem Q10-Min (secção 3.2.3). A diferença é que os agentes *manager* seguem agora uma estratégia de *melhor utilidade* aquando da seleção da solução candidata, de entre o conjunto de soluções candidatas apresentadas pelos agentes especialistas. É com a solução candidata assim escolhida que se dará início à negociação entre *managers*.

3.2.5 Q10-Best-Filter

Esta abordagem é semelhante à abordagem Q10-Best (secção 3.2.4). A diferença é que os agentes *manager* descartam agora soluções candidatas apresentadas pelos agentes especialistas que não sigam a ação sugerida pelo Q-Learning. Também são descartadas as soluções que não sigam o operador de domínio¹ sugerido pelo mesmo mecanismo de aprendizagem Q-Learning. Esta *pequena* diferença reduz o número de soluções candidatas disponíveis para serem selecionadas pelos *managers*.

3.2.6 Q20-Best

Esta abordagem é semelhante à abordagem Q10-Best (secção 3.2.4), contudo, em vez de existir um máximo de dez soluções candidatas por cada agente *manager*, existem vinte. Isto significa que os agentes *managers* têm mais opções de escolha, aumentando a possibilidade de atingir maiores valores de utilidade.

3.2.7 S10-Best

Esta abordagem é semelhante à abordagem Q10-Best (secção 3.2.4), sendo a diferença o uso do algoritmo de aprendizagem SARSA em vez de Q-Learning.

3.2.8 S10-Best-Filter

Esta abordagem é semelhante à abordagem Q10-Best-Filter (secção 3.2.5), sendo a diferença o uso do algoritmo de aprendizagem SARSA em vez de Q-Learning.

3.2.9 S20-Best

Esta abordagem é semelhante à abordagem Q20-Best (secção 3.2.6), sendo a diferença o uso do algoritmo de aprendizagem SARSA em vez de Q-Learning.

3.2.10 Q10-Best-V2

Esta abordagem é semelhante à abordagem Q10-Best (secção 3.2.4), contudo foram introduzidas algumas alterações no que diz respeito à forma como o mecanismo de aprendizagem é

¹ Ações usadas pelo operador humano na resolução de um problema

utilizado. A ideia principal desta abordagem é perceber o impacto da não utilização de mecanismos de aprendizagem na negociação entre *managers*.

Nesta abordagem não é utilizada aprendizagem na negociação entre *managers*: os agentes *manager*, em resposta a um pedido do *manager* que iniciou a negociação, cumprem com as restrições impostas mas, em vez de escolher a melhor solução candidata parcial com base no mecanismo de aprendizagem, escolhem aquela que tem mais utilidade para si. Isto faz com que o número de soluções candidatas parciais disponíveis para seleção seja maior por parte do agente *manager*.

3.2.11 Q20-Best-V2

Esta abordagem é semelhante à abordagem Q10-Best-V2 (secção 3.2.10), sendo a diferença o facto de existir um máximo de vinte soluções candidatas por agente *manager*, e não dez.

3.3 Limitações

O atual sistema MASDIMA, como qualquer protótipo, apresenta algumas limitações. As limitações mais relevantes estão relacionados com dois tópicos: interação com utilizadores humanos e eficiência temporal na resolução de problemas. O trabalho desta dissertação é motivado por algumas destas limitações do protótipo MASDIMA.

Em relação ao primeiro tópico, é importante que o sistema, para além de fornecer soluções aos problemas em questão, o faça de uma maneira previsível e que gere confiança nos operadores humanos que o supervisionam. Será útil que o sistema interaja e receba a opinião de humanos acerca das soluções encontradas. Esta dissertação não lida diretamente com a interação com o utilizador humano mas permite, como veremos nos próximos capítulos, que as decisões tomadas pelo sistema possam ser influenciadas por quem constrói a base de conhecimento do sistema, tarefa que pode ser realizada por operadores humanos.

No que diz respeito ao segundo tópico, um dos principais objetivos, já identificados no capítulo de Introdução (secção 1.2), é o de minimizar o tempo entre o instante em que um problema chega ao sistema e o instante em que é fornecida uma solução. Para situações em que a rotura ocorre mesmo em cima da hora de partida do voo, o atual protótipo pode não ser capaz de fornecer uma resposta em tempo útil, tornando a sua solução inconsequente. O trabalho desta dissertação vem fornecer hipóteses de resolução para estas situações.

3.4 Resumo

O objetivo deste capítulo foi a apresentação sumária do protótipo MASDIMA, que será usado na realização do trabalho desta dissertação.

Começamos por fazer uma pequena introdução à estrutura do sistema, destacando os aspetos mais relevantes para o trabalho a desenvolver na presente dissertação. Não foi nossa intenção fazer uma descrição detalhada e exaustiva do protótipo, uma vez que o mesmo se encontra devidamente

Protótipo Existente

documentado em Castro (2013), mas antes fornecer ao leitor a definição essencial do sistema para permitir a compreensão dos capítulos que se seguem.

Foram também apresentadas as abordagens já implementadas no sistema MASDIMA, sendo que algumas delas serão posteriormente utilizadas na comparação com as abordagens desenvolvidas no âmbito desta dissertação.

Por fim, foram enumeradas algumas das limitações do protótipo existente, que motivaram o trabalho aqui realizado.

Protótipo Existente

Capítulo 4

Conceção e Implementação

O problema em análise é o de transpor a abordagem CBR para o âmbito da aviação civil, nomeadamente na gestão de roturas nos Centros de Controlo Operacional. A componente de aprendizagem com o passado através de CBR será adicionada ao sistema MASDIMA.

Neste capítulo, será feita a dissecação do módulo de aprendizagem com o passado que foi adicionado ao sistema MASDIMA, procurando-se descrever o problema, identificar as metodologias aplicadas durante a implementação e apresentar as modificações introduzidas na metodologia CBR. Estas alterações deram origem a uma nova metodologia, baseada em CBR, para ambientes dinâmicos e distribuídos.

4.1 Descrição do Problema

O objetivo desta secção é descrever, com exatidão, a forma como é modelado o problema (subsecção 4.1.1), como se faz a comparação entre casos (subsecção 4.1.2) e o que se entende por solução (subsecção 4.1.3).

4.1.1 Problema

Um problema, no contexto do sistema MASDIMA, é um atraso, à partida, de um voo, sendo originado por eventos. Um caso, será a descrição total de um problema (incluindo informações do evento que lhe deu origem) e a solução encontrada para esse problema.

A criação de casos tipo no âmbito da gestão de roturas nos Centros de Controlo Operacional (CCO) é desaconselhada dado tratar-se de um ambiente muito volátil, onde é difícil generalizar os problemas. Desta forma, e neste contexto específico, um problema dará origem a um novo caso, que será mais tarde, quase sempre, retido na base de conhecimento.

A definição e forma de armazenamento de um caso é uma das questões fundamentais da abordagem proposta nesta dissertação. A correta determinação do grau de similitude entre casos, especialmente numa ambiente tão dinâmica como o da gestão de roturas nos CCO, é uma das chaves para o sucesso da implementação, necessitando de estar, por isso, estas duas fases interligadas desde a sua especificação.

Para o início da estruturação de um caso, no contexto desta abordagem, foram analisadas as variáveis de um evento no sistema MASDIMA, que se encontram na tabela 4.1 (foram intencionalmente omitidas outras variáveis por não serem relevantes no âmbito desta dissertação).

Tabela 4.1: Variáveis de um evento no sistema MASDIMA

Nome	Tipo	Descrição
event_time	Data/Hora	Data e hora em que o evento foi detetado
event_cause	Enumeração	Causa do evento (tabela 4.2)
resource_affected	Texto	Código do recurso afetado
resource_type	Texto	Tipo de recurso afetado
resource_cap	Numérico	Capacidade do recurso afetado
crew_res_type	Texto	Tipo de tripulação utilizada
flight_date	Data	Data do voo
flight_num	Numérico	Número do voo
scheduled_time_of_departure	Data/Hora	Data e hora prevista para a partida do voo
scheduled_time_of_arrival	Data/Hora	Data e hora prevista para a chegada do voo
origin	Texto	Código do aeroporto de origem
destination	Texto	Código do aeroporto de destino
bus_pax	Numérico	Número de passageiros em classe executiva
econ_pax	Numérico	Número de passageiros em classe económica
total_pax	Numérico	Número total de passageiros
scheduled_trip_time	Hora	Tempo previsto para a viagem

A causa de cada evento é um dos fatores principais na produção de uma solução a propor, sendo, por isso, um facto importante na comparação de casos.

As causas de eventos, presentes na tabela 4.2, são aquelas definidas no sistema MASDIMA. Para cada uma das causas identificadas foram definidas as variáveis mais importantes, tendo em conta informações obtidas por parte de especialistas da empresa TAP Portugal. Estas informações podem ser consultadas na tabela 4.3.

Infelizmente, e porque a análise dos dados deste domínio específico é bastante complexa e a construção de casos virtuais é de difícil execução, não nos foi possível obter uma dimensão de casos que possibilitasse outro tipo de análise, nomeadamente uma análise estatística de aglomeração e classificação de dados, de forma a podermos perceber se existiam outras variáveis que, à primeira vista, foram descuradas, mas que poderiam, eventualmente, ser relevantes na diferenciação de problemas. Todavia, e como é possível observar no capítulo 5, os resultados obtidos permitem-nos dizer que a definição feita é suficiente para a análise que nos propusemos realizar.

Tabela 4.2: Tipos de Causas de Eventos

Código	Designação	Descrição
AIRP	Aeroporto	Infraestrutura e serviços aeroportuários. Por exemplo, locais de estacionamento insuficientes, problemas com serviços de estrangeiros e fronteiras, segurança, entre outros.
ATC	Controlo de Tráfego Aéreo	Restrições em rota, ou no destino, e condições meteorológicas.
COMM	Controlo de Passageiros	Proteção de passageiros em outros voos devido ao cancelamento de um voo. Passageiros em falta após <i>check-in</i> .
CROT	Rotação de Tripulação	Falta de membro da tripulação devido a atraso de um voo anterior ou outros problema relacionados com a rotação da tripulação.
HAND INDUTY	Manuseamento Em serviço	Atraso com embarque de passageiros ou carga. Membro da tripulação em falta depois da apresentação para voo, ou doença ou acidente durante o voo ou a estadia.
MAINT	Manutenção	Avaria da aeronave ou outros problema relacionados com manutenção.
METEO ROT	Meteorologia Rotação	Condições meteorológicas no aeroporto de partida. Eventos relacionados com rotação de aeronave. Por exemplo, atraso em voo anterior.
RULES	Legislação	Eventos relacionados com o cumprimento de regras e leis. Por exemplo, o excesso de horas de trabalho diário de membro da tripulação.
SEC SIGN OTH	Bagagem Tripulação em Falta Outros	Identificação, procura e recuperação de bagagem. Não comparência de membro da tripulação na base. Eventos não contemplados nas categorias anteriores.

Tabela 4.3: Variáveis mais relevantes para cada causa de evento

Causa	Variável 1	Variável 2	Variável 3	Variável 4
AIRP	origin	flight_num	schedule_time_of_departure (hora)	resource_type
ATC	destination	origin	schedule_time_of_arrival (hora)	flight_num
COMM	flight_num	schedule_time_of_departure (dia da semana)	origin	destination
CROT	flight_num	schedule_time_of_departure (dia da semana)	origin	destination
HAND INDUTY	origin crew_res_type	flight_num flight_num	schedule_time_of_departure schedule_time_of_departure (hora)	resource_type schedule_time_of_departure (dia da semana)
MAINT METEO	resource_affected origin	resource_type schedule_time_of_departure (hora)	resource_cap schedule_time_of_departure (época do ano)	origin resource_type
ROT	flight_num	origin	resource_type	destination
RULES	flight_num	schedule_time_of_departure (hora)	origin	destination
SEC	resource_affected	resource_type	origin	destination
SIGN	flight_num	schedule_time_of_departure (dia da semana)	origin	destination
OTH	Todas as variáveis têm o mesmo peso			

4.1.2 Função de Similitude

Tendo as variáveis definidas (tabela 4.3) cabe, agora, identificar a função para a determinação da similitude entre dois casos com a mesma causa.

A função definida foi:

$$f(Caso_1, Caso_2) = \sum_{i=1}^4 a_i x_i, \quad \text{com} \quad (4.1)$$

$$\sum_{i=1}^4 a_i = 1, \quad a_i \in [0, 1] \quad \text{e} \quad x_i \in [0, 1]$$

sendo que i é cada uma das quatro variáveis definidas para cada causa (tabela 4.3); x_i é o valor da comparação entre $Caso_1$ e $Caso_2$ na variável i ; e a_i a ponderação de cada variável na função de similitude. A forma de obtenção do valor x_i para as variáveis do tipo Data, Hora ou Data/Hora encontra-se explicada na subsecção 4.2.2.

A função de similitude foi assim definida dado procurarmos uma função com contradomínio pertencente ao intervalo $[0, 1]$, e que seja, simultaneamente, flexível, possibilitando a sua adaptação conforme as preferências de cada companhia aérea em cada momento.

O peso a atribuir a cada uma das variáveis da função pode ser facilmente introduzido no sistema desenvolvido. Caso a quantidade de dados o permita, a nossa recomendação é que se realize um passo adicional utilizando, por exemplo, uma rede neuronal, de forma a obter os pesos ideais para cada variável. Na nossa implementação, os pesos atribuídos a cada variável baseiam-se na opinião de especialistas da TAP Portugal e podem ser consultados no capítulo 5.

4.1.3 Solução

Uma solução, no contexto do nosso sistema, é o conjunto de ações realizadas na resolução de um problema. Este conjunto é composto, tipicamente, por três ações (uma relativa a cada dimensão). As ações das respetivas dimensões podem ser consultadas nas tabelas 4.4, 4.5 e 4.6 (Castro, 2013).

Tabela 4.4: Ações possíveis para a dimensão Avião

Ação	Descrição
<i>cancel</i>	Cancelar o voo
<i>delay</i>	Atrasar o voo um número específico de minutos
<i>exchange</i>	Trocar a aeronave por outra de outro voo
<i>other</i>	Alugar tripulação e aeronave a outra companhia (<i>wet lease</i> (Beyhoff, 1995))

Para o correto armazenamento das soluções foi criada uma estrutura de dados adicional, indexada a cada caso da base de casos. Estas estruturas compreendem todos os dados relativos às características da solução que serão, posteriormente, tratados por parte dos agentes *manager* e especialistas, como explicado com mais detalhe na secção 4.2.3.

Tabela 4.5: Ações possíveis para a dimensão Tripulação

Ação	Descrição
<i>accept_delayed_crew</i>	Utilizar o tripulante com atraso no voo, o que implica aceitar o atraso do voo.
<i>exchange_crew</i>	Trocar o tripulante atrasado por outro de outro voo.
<i>other</i>	Propor troca de avião e/ou cancelar o voo.
<i>proceed_without_crew</i>	O voo será realizado sem o tripulante atrasado.
<i>use_crew_on_vacation</i>	Utilizar tripulante em férias para realizar o voo.
<i>use_dayoff_crew</i>	Utilizar tripulante em dia de descanso para realizar o voo.
<i>use_free_time_crew</i>	Utilizar tripulante disponível e sem voo atribuído.
<i>use_reserve_crew</i>	Utilizar tripulante de reserva.

Tabela 4.6: Ações possíveis para a dimensão Passageiros

Ação	Descrição
<i>change_flight_change_airline</i>	Alterar o passageiro para outro voo de outra companhia aérea.
<i>change_flight_same_airline</i>	Alterar o passageiro para outro voo da mesma companhia.
<i>keep_same_flight</i>	Manter o passageiro no mesmo voo.

Dada a dinâmica do ambiente, já perspectivávamos que a reutilização e adaptação de soluções dos problemas fosse uma tarefa muito complicada de transpor para uma implementação prática. A constante mudança das condições do ambiente torna, muitas vezes, a transposição de uma solução completa encontrada anteriormente impossível para o caso atual. Tendo por certa esta barreira, não é menos verdade que, embora a solução não seja passível de ser transposta de maneira automática, a ideia permanece, isto é, apesar de a solução não ser exatamente a mesma, a forma de resolução subjacente permanece intacta.

Como veremos mais à frente, a necessidade de adaptar a metodologia CBR a ambientes dinâmicos levou à introdução de alterações no protocolo CBR tradicional. Estas mudanças possibilitaram a aplicação de CBR neste contexto.

4.2 Metodologias Aplicadas

Nesta secção serão abordadas as metodologias e algoritmos identificados na descrição do problema na secção 4.1. Iremos começar por descrever a forma de armazenamento da base de conhecimento (subsecção 4.2.1), como será feita a recuperação dos casos mais semelhantes (subsecção 4.2.2), como se irá proceder à reutilização e adaptação das soluções encontradas (subsecção 4.2.3) e, por fim, como se irá realizar a retenção de novos casos na base de conhecimento (subsecção 4.2.4).

4.2.1 Base de Conhecimento

Como foi referido na subsecção 4.1.1, a causa de cada evento é um ponto fundamental na comparação de casos. A arquitetura para o armazenamento da base de conhecimento deve refletir esta importância. A implementação feita baseia-se na criação de *clusters* de dados, com base no atributo *event_cause*, utilizando uma base de dados relacional, com uma tabela para cada tipo de evento (figura 4.1).

A distribuição da ocorrência de cada um dos tipos de causas de eventos identificadas na tabela 4.2 não é linear, pelo que, no início, se previu a necessidade de, nos tipos de causas com mais frequência, criar novos *clusters* com base numa ou mais variáveis de forma a minimizar o número de casos a comparar diretamente, sem colocar em causa a qualidade dos casos identificados como similares. Contudo, dado que a quantidade de casos que foram possíveis recolher não foi elevada, e como foi dada, desde o início da implementação do módulo de aprendizagem com o passado no sistema MASDIMA, uma especial importância ao seu desempenho, não houve necessidade de recorrer a um segundo processo de *clustering*.

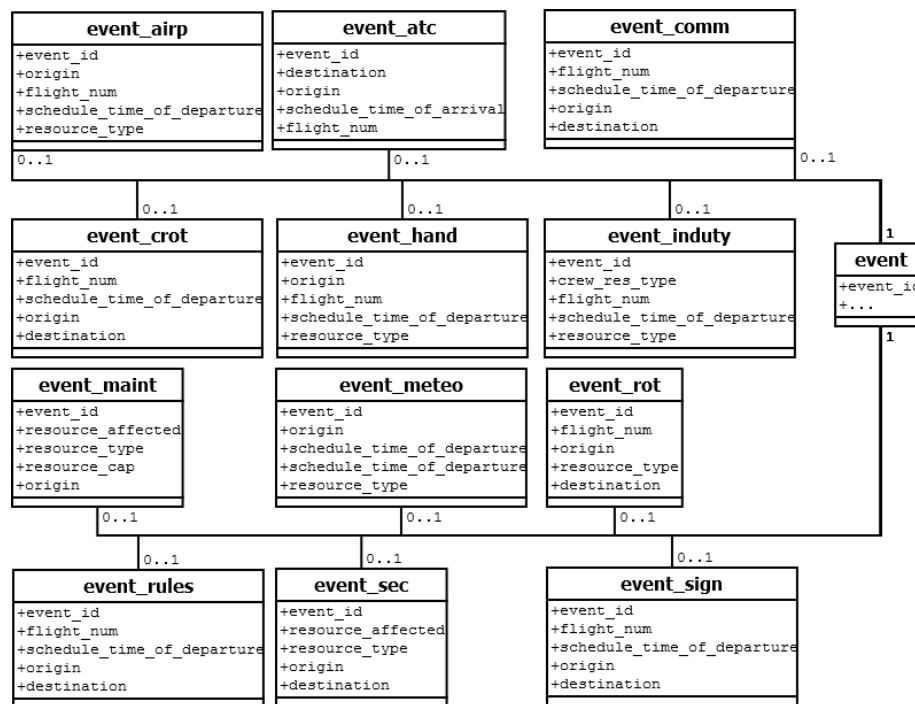


Figura 4.1: Diagrama de classes UML para armazenamento de eventos

Para além da informação relativa aos problemas que originaram casos, a nossa base de conhecimento contém ainda informação sobre as soluções utilizadas em cada caso. Cada solução, como descrito na subsecção 4.1.3, é composta pelas ações a executar em cada uma das dimensões do problema. Ao contrário do armazenamento dos casos, entendemos que não é necessário proceder ao *clustering* das soluções, uma vez que não é necessário efetuar pesquisas pelas soluções mas, somente, a um registo específico de cada vez. O diagrama de classes UML para a tabela *solution_plan* pode ser encontrado na figura 4.2.




Figura 4.2: Diagrama de classes UML para armazenamento de soluções

4.2.2 Recuperação

Para ser possível recuperar casos da base de conhecimento é necessário haver uma pesquisa, comparando o novo caso, que acabou de entrar no sistema, com os casos previamente retidos. O novo caso será comparado com todos aqueles já existentes no sistema que tenham o mesmo tipo de causa, sendo posteriormente aferido o seu grau de similitude (equação (4.1) consoante o seu tipo.

A comparação das variáveis do tipo Data e Data/Hora foi feita através da obtenção do tempo decorrido entre eventos, sendo que, em geral, quanto menor for esta diferença maior será o grau de similitude. Para se alcançar esse objetivo foram utilizadas as seguintes funções de conversão de valor:

$$g(\Delta t) = a \times b^{-\lambda \Delta t}, \quad \lambda > 0, \quad \Delta t \geq 0 \quad (4.2)$$

$$j(\Delta t) = \frac{\cos(\alpha(\Delta t)) + |\cos(\alpha(\Delta t))|}{2}, \quad \alpha(\Delta t) = \frac{2\pi}{\lambda'} \times \Delta t, \quad \lambda' > 0, \quad \Delta t \geq 0 \quad (4.3)$$

onde Δt é a diferença temporal entre os momentos em que ocorreram o novo caso e o caso em comparação e $g(\Delta t)$ o grau de similitude da variável em questão. Os fatores λ e λ' são constantes positivas, que podem ser ajustadas de acordo com as necessidades de cada variável temporal a comparar, com o objetivo de modelar melhor as comparações entre diferentes unidades de tempo (minutos, horas, dias, semanas ou meses).

As figuras 4.3 e 4.4 representam instâncias das funções 4.2 e 4.3 respetivamente. Os valores para os parâmetros a , b , λ e λ' foram escolhidos de forma a que as funções resultantes revelassem os comportamentos desejados para as situações que, de seguida, se descrevem. Assim, para o primeiro exemplo (figura 4.3), quando a diferença entre tempos for nula, a similitude é máxima, decrescendo com o aumento da diferença temporal, sendo que, acima de determinada valor de t , a diferença temporal torna-se tão grande que a similitude aproxima-se de zero, ou seja, os casos em nada são semelhantes nesta variável, se o tempo decorrido entre elas for considerado grande. No segundo caso (figura 4.4), estamos perante uma função periódica que permite a comparação temporal em termos cíclicos (por exemplo, de estações do ano), pertinente para a comparação de variáveis relacionadas com fatores meteorológicos.




Figura 4.3: Função $g(\Delta t)$ (4.2), $a = 1, b = e, \lambda = 1$




Figura 4.4: Função $j(\Delta t)$ (4.3), $\lambda' = 365$

4.2.3 Reutilização e Adaptação

A reutilização e adaptação de casos, numa área tão dinâmica como a da gestão de roturas na aviação civil, é um dos maiores problemas que uma abordagem baseada em conhecimento passado pode encontrar. A volatilidade da conjuntura em função do tempo é um fator que pode contribuir para a diminuição da qualidade das soluções encontradas.

Tendo em consideração que um dos objetivos do nosso trabalho visa, sobretudo, diminuir o tempo necessário para que uma solução seja apresentada sem colocar em causa a qualidade das soluções, a proposta aqui desenvolvida é a da utilização de um sistema misto. Isto é, através da técnica de CBR, o agente Supervisor pesquisará os três casos mais semelhantes com o novo

problema a resolver, contidos na base de conhecimento. Os agentes *manager*, começando pelo caso mais semelhante, pedem soluções aos seus agentes especialistas que respeitem a ação da sua dimensão. Os agentes especialistas, por sua vez, em vez de tentarem adaptar a solução passada no caso mais semelhante, como fariam num processo típico de CBR, irão gerar uma solução completamente nova, mas tendo como ponto de partida a ação proveniente da solução presente no caso mais semelhante.

A passagem dos três casos mais semelhantes, do agente Supervisor para os agentes *manager*, dá-se pelo facto de nem sempre um agente especialista poder ser capaz de gerar uma solução utilizando a mesma ação presente no caso. Por exemplo, imaginando um cenário onde a ação para a dimensão avião, presente no caso mais semelhante, é *exchange* e, simultaneamente, não existe nenhuma aeronave disponível para substituição, irá gerar-se uma situação onde os agentes especialistas não serão capazes de gerar uma solução exequível. Assim que todos os agentes especialistas reportem tal situação ao seu agente *manager*, o agente *manager* irá automaticamente enviar o segundo caso mais semelhante, e assim sucessivamente. Caso nenhum dos casos mais semelhantes tenha originado uma solução válida, então o problema é declarado como irresolúvel e é aceite o atraso já previsto no sistema.

Na negociação intermanager (ver secção 3.1), o agente que inicia esta negociação pode optar, dependendo da abordagem utilizada, por impor as ações presentes no caso para as restantes dimensões como restrições às soluções propostas pelos outros agentes *manager*.

4.2.4 Retenção

O atual sistema MASDIMA já contemplava o armazenamento de problemas numa base de dados relacional. Esta solução foi reaproveitada na abordagem sugerida, sendo introduzidas as alterações necessárias para que os novos casos possam ser inseridos na estrutura de dados explicada na subsecção 4.2.1.

No que diz respeito à seleção dos casos para retenção, todos os novos casos são retidos na base de conhecimento, exceto aqueles que apresentem uma utilidade para o Supervisor (\overline{U}_{sup} , definição B.2.1) inferior a 75%, situação na qual consideramos que a solução não apresenta qualidade suficiente para ser armazenada.

Casos com mais de dezoito meses são automaticamente eliminados da base de conhecimento, uma vez que consideramos que passado este tempo os casos deixam de ter relevância. O período de dezoito meses foi escolhido porque, por um lado, é importante proceder à eliminação de casos antigos cujas soluções já se encontram ultrapassadas, mantendo a base de conhecimento com uma dimensão razoável e, por outro lado, porque entendemos que este período permite comparações entre casos que derivem de situações sazonais, como, por exemplo, razões meteorológicas ou relativas a férias de colaboradores.

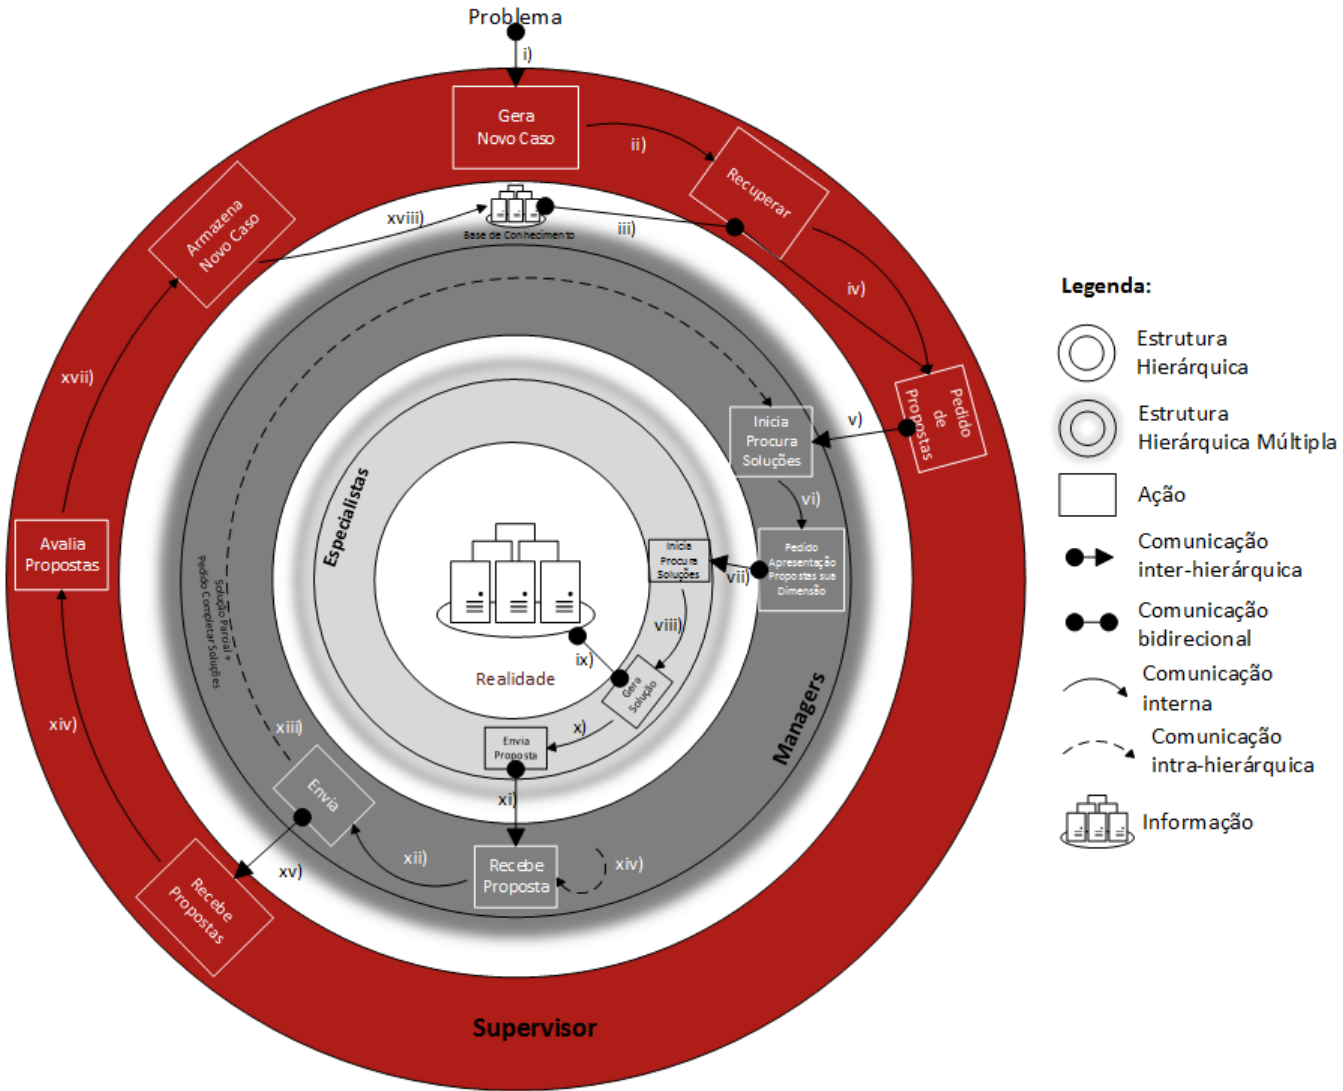


Figura 4.5: Ciclo CBR-DDE

4.3 Case-based Reasoning Distribuído em Ambientes Dinâmicos

A descrição efetuada do problema e as metodologias aplicadas levaram à criação de uma nova metodologia. Esta nova metodologia (figura 4.5) baseia-se na transposição do ciclo CBR tradicional (figura 2.1) para um ambiente distribuído e vem tornar possível a utilização de *Case-based Reasoning* em ambientes dinâmicos. A esta nova metodologia chamamos **Case-based Reasoning Distribuído em Ambientes Dinâmicos** (CBR-DDE¹).

À semelhança da metodologia tradicional, o ciclo inicia-se com a ocorrência de um problema que origina a geração de um novo caso (i) por parte do agente Supervisor. Este agente de seguida tenta recuperar (ii) os casos mais semelhantes presentes na base de conhecimento, através de uma pesquisa (iii). Após a pesquisa, o novo caso e os casos mais semelhantes são preparados (iv) para serem enviados para os agentes *manager* (v), que são convocados para fornecerem soluções para o novo caso.

Cada agente *manager* (representado na figura 4.5 como uma estrutura hierárquica múltipla a cinza escuro) inicia uma pesquisa por soluções através de uma convocatória aos agentes especialistas (vi), enviando o caso mais semelhante da base de conhecimento e o caso atual (vii). Cada especialista irá então dar início à geração de uma solução para o novo caso (viii).

A geração da solução implica o acesso aos recursos disponíveis em cada momento (ix) e, dependendo da abordagem utilizada, o agente *manager* pode requerer aos seus especialistas que apenas gerem soluções que utilizem a ação do caso mais semelhante. Após o agente especialista ter gerado uma solução (x), este envia-a para o seu agente *manager* (xi).

Quando o agente *manager* recebe as soluções dos agentes especialistas da sua dimensão (xi), escolhe a solução que tem um maior valor de utilidade para si (equações 3.1, 3.2 e 3.3) (xii) e convoca os restantes agentes *manager* para que completem a sua solução (xiii). Após receber as soluções das restantes dimensões (xiv), o agente *manager* compila estas soluções numa única solução integrada (xi) e envia-a para o agente Supervisor (xv).

Após receber as propostas de todos os agentes *manager* (xv), o agente Supervisor avalia-as, utilizando a equação 3.4 (xvi), e escolhe a melhor proposta (xvii). Se a utilidade (U_{sup}) do novo caso for superior a 75% então o novo caso, já resolvido, é armazenado na base de conhecimento (xviii). O valor 75% foi definido com base nas experiências realizadas à medida que a metodologia foi sendo desenvolvida e testada no nosso cenário. Em cenários distintos poderá haver lugar a alteração deste valor.

A inovação nesta metodologia situa-se, principalmente, na forma de gerar a solução e na distribuição do CBR por várias entidades.

Na geração da solução, enquanto que as implementações tradicionais (Bradley P. Allen, 1994; Park et al., 2006) fazem uma reutilização e adaptação parcial das soluções dos casos presentes na base de conhecimento, a nossa metodologia cria uma solução completamente nova, tendo por base o ambiente atual e atualizado, mas utilizando os princípios de resolução manifestados na solução do caso mais semelhante presente na base de conhecimento. Esta abordagem permite-nos utilizar

¹do inglês: *Case-based Reasoning - Distributed for Dynamic Environments*

os fundamentos do CBR, onde se acredita que problemas similares têm soluções similares (Krusmaa, 2003), ao mesmo tempo que tornamos possível a sua aplicação em ambientes dinâmicos. Esta forma de adaptação onde, em vez de adaptarmos parcialmente uma solução, construímos uma outra totalmente de raiz, abre novas aplicações para o CBR e vem romper com a forma de adaptação até agora descrita na literatura (Aamodt e Plaza, 1994; Bradley P. Allen, 1994; De Mantaras et al., 2005; Urdiales et al., 2006).

A distribuição do CBR por várias entidades vem agilizar todo o processo, pois vários problemas podem estar a ser resolvidos em *pipeline*, tirando partido das plataformas *multi-core*. Esta distribuição permite ainda a existência de nós redundantes, deslocalizados e distribuídos, o que é um aspeto muito importante em sistemas críticos.

O diagrama de sequência UML, que descreve a implementação da metodologia CBR-DDE, no sistema MASDIMA, pode ser consultado na figura 4.6.

Sendo o sistema MASDIMA um sistema multiagente, onde todas as informações são trocadas através de eventos, foi necessário implementar um conjunto de *handlers* para lidar com estes eventos assincronamente.

Conceção e Implementação

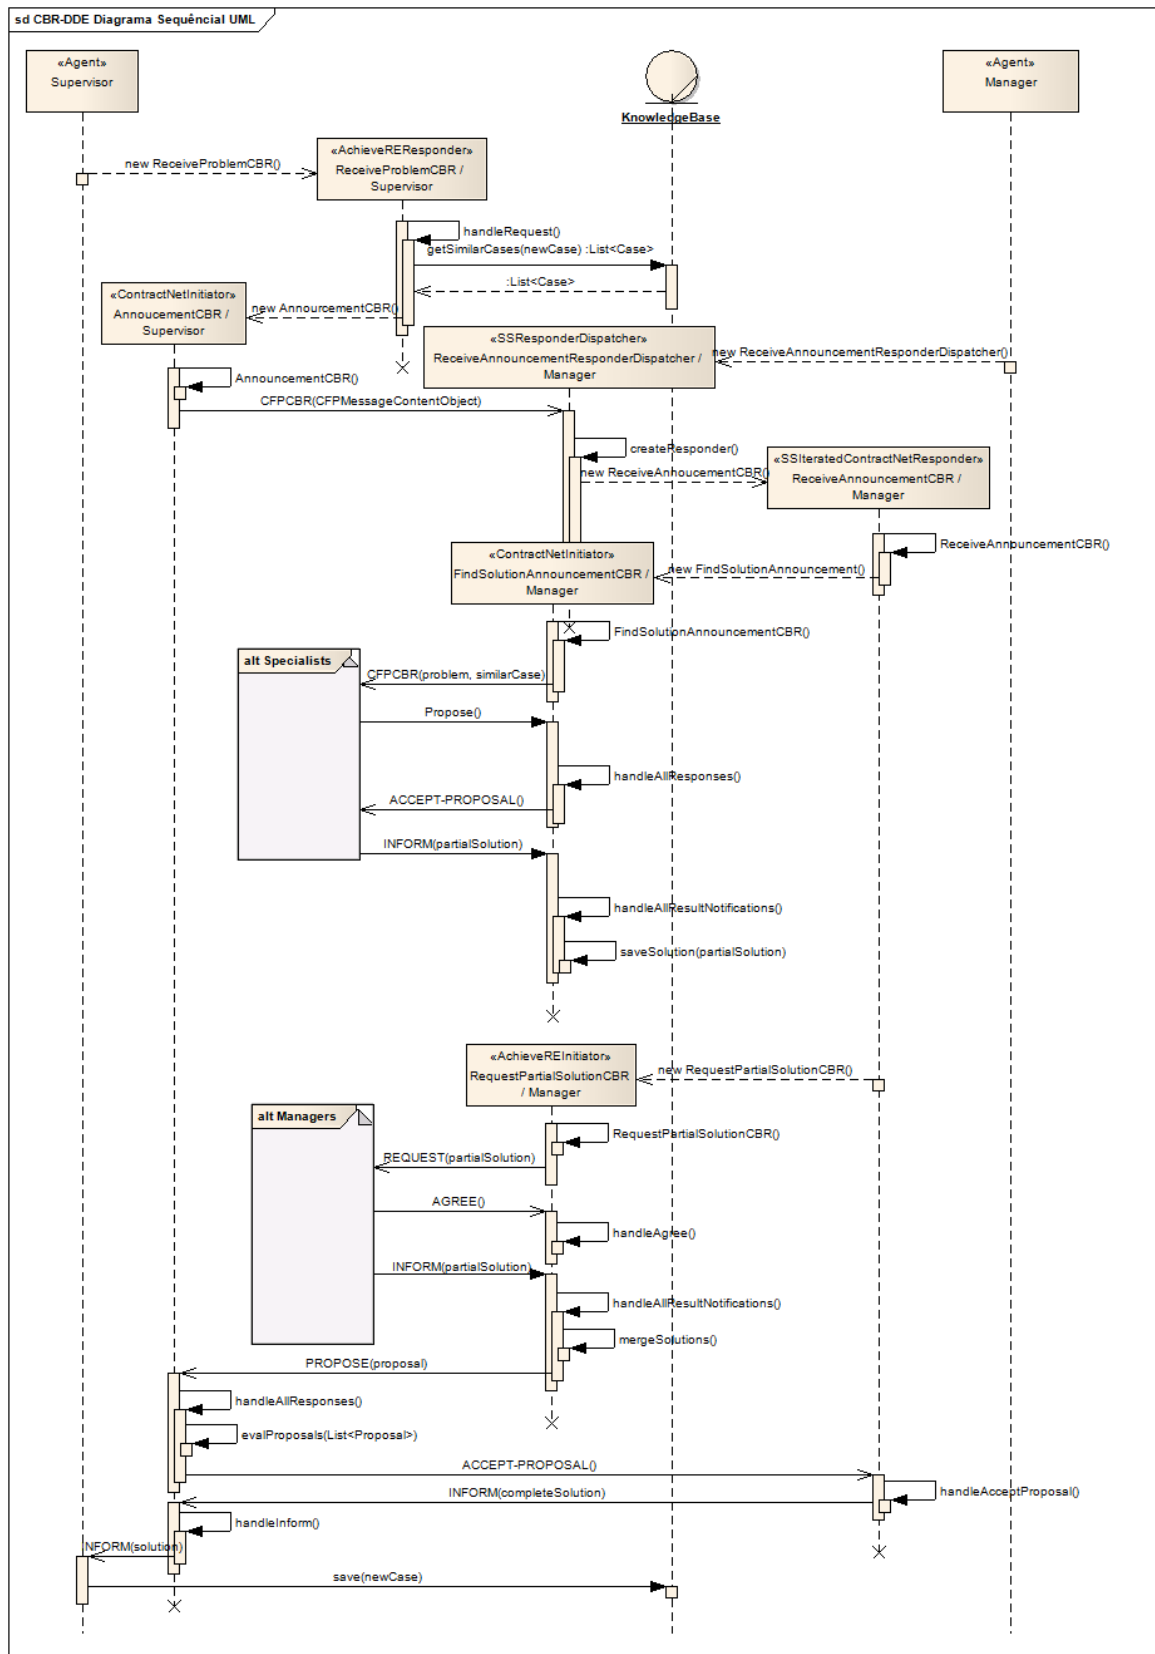


Figura 4.6: Diagrama de Sequência UML - CBR-DDE MASDIMA

4.4 Resumo

Neste capítulo foi formalizado o problema a tratar, indicadas as metodologias utilizadas na sua resolução e introduzida a metodologia CBR-DDE, uma inovação que veio resolver um dos principais obstáculos à implementação de metodologias baseadas em CBR em ambientes dinâmicos, como é o caso da gestão de roturas nos Centros de Controlo Operacional das companhias aéreas.

Foi descrito o que é um problema e um caso neste contexto incluindo a noção de solução. Indicamos, também, as principais causas dos eventos tratados pelo MASDIMA, as variáveis mais relevantes para cada tipo de evento e a função de similitude usada na comparação de casos. Na descrição das metodologias a usar, foi descrito, passo a passo, o ciclo CBR, indicando-se métodos, algoritmos e funções a utilizar em cada uma das etapas. A cuidadosa análise do problema a resolver e das metodologias a aplicar em cada um dos passos do ciclo CBR permitiu-nos construir uma nova metodologia, baseado no ciclo CBR de Aamodt e Plaza (figura 2.1). Esta nova metodologia, que introduz mudanças significativas no processo de reutilização/adaptação face ao ciclo CBR tradicional, elimina alguns dos obstáculos existentes à utilização de CBR na resolução de problemas em ambientes dinâmicos.

Capítulo 5

Experiências e Avaliação

Este capítulo versa sobre as experiências que projetamos e levamos a cabo para verificar se os objetivos referidos na secção 1.2 foram ou não atingidos, seguindo a estrutura presente em Castro (2013).

Na secção 5.1 detalhamos o cenário usado na reutilização das experiências relacionadas com a gestão de ruturas num CCO. Na secção 5.1.1 apresentamos algumas métricas definidas em Castro (2013) e identificamos e definimos métricas adicionais para analisar os resultados obtidos em cada uma das diferentes abordagens utilizadas nas experiências realizadas. Incluímos métricas relacionadas com *transporte aéreo*, *desempenho negocial* e *desempenho do protocolo*. Na secção 5.1.2 detalhamos as abordagens utilizadas para executar as experiências, isto é, os diferentes métodos utilizados na tentativa de resolução de problemas, incluindo métodos já previamente desenvolvidos no âmbito do projeto MASDIMA (capítulo 3).

Na secção 5.2 apresentamos os resultados das experiências e realizamos a sua análise, recorrendo às métricas previamente definidas na secção 5.1.1.

Terminamos o capítulo com um resumo (secção 5.3), destacando os tópicos mais relevantes.

5.1 Cenário

Nesta secção detalhamos o cenário preparado para realizar as experiências, incluindo a caracterização da informação utilizada e dos problemas a resolver. Idealmente, para testar os objetivos apresentados na secção 1.2, deveríamos utilizar os dados de um ano completo de operações aéreas da TAP Portugal. O ramo dos transportes aéreos tem comportamentos sazonais (Castro, 2013), fazendo com que cada mês seja diferente no que diz respeito à ocorrência de eventos que causem roturas.

A tabela 5.1 mostra a distribuição, em percentagem, dos atrasos dos voos da TAP Portugal, entre Abril de 2009 e Abril de 2010, em função da causa que provocou o atraso (causas descritas na tabela 4.2).

Infelizmente, o plano operacional da TAP Portugal, para um ano, corresponde a vários *terabytes* de dados, o que torna impossível o tratamento e análise de todo o plano em tempo útil. Por

Experiências e Avaliação

Tabela 5.1: Distribuição mensal, em percentagem, dos atrasos na TAP Portugal entre Abril 2009 e Abril 2010

Mês	AIRP	ATC	COMM	HAND	MAINT	METEO	CREW	ROT	SEC	OTH
Abr 09	11	14	5	17	11	1	9	15	13	4
Mai 09	10	18	6	14	9	1	8	16	15	3
Jun 09	10	19	7	15	8	1	8	17	12	3
Jul 09	9	22	6	19	7	1	8	17	10	2
Ago 09	7	18	5	20	8	1	7	20	10	4
Set 09	10	17	5	17	7	1	9	20	11	3
Out 09	8	25	3	17	10	3	10	10	11	2
Nov 09	6	23	5	16	10	4	11	12	10	3
Dez 09	7	21	5	15	5	4	8	26	7	2
Jan 10	6	20	4	14	8	6	9	23	8	2
Fev 10	17	21	5	14	8	4	11	11	7	2
Mar 10	19	8	6	18	10	3	12	10	10	3
Abr 10	16	9	4	22	9	4	13	12	9	2
Média	11	18	5	17	9	3	9	16	10	3

outro lado, e de forma a que os resultados obtidos nas nossas novas abordagens pudessem ser comparáveis com os resultados das abordagens anteriormente desenvolvidas, optamos por nos cingir ao mês de setembro, como previamente definido em Castro (2013). Para ajudar o leitor, decidimos incluir, também aqui, essas informações.

Tabela 5.2: Informação disponível no ambiente de teste utilizado

Nome da Tabela	Descrição
Atividades	Lista de atividades dos tripulantes
Modelos de Aeronaves	Capacidade e custos médios por modelo de aeronave, incluindo custos por milha náutica, manutenção, combustível e custos de operação
Aeronaves	Lista de aeronaves disponíveis
Taxas aeroportuárias	Taxas aeroportuárias aplicadas em cada aeroporto
Emparelhamento de Aeroportos	Latitude, Longitude e Distância entre dois aeroportos
Tripulantes	Grupo, categoria e horas de voo de cada tripulante
Eventos	Eventos que causaram problemas ao plano operacional
Voos	Escalonamento de voos programado
Tarifas hoteleiras	Custos hoteleiros para passageiros e tripulantes
Salários	Informação salarial dos tripulantes

O mês de setembro de 2009 foi utilizado como referência em Castro (2013) por possuir características similares à média de um ano de operações. Para além de informação relacionada com o escalonamento de tripulação, aeronaves e voos, também foram incluídas informações relacionadas com custos operacionais, isto é, custos com: tripulação (salários, custos hoteleiros, etc), aeronaves (serviço e manutenção, combustível, taxas aeroportuárias, etc) e passageiros (compensações, perda de confiança, etc), como se pode consultar na tabela 5.2. Detalhes sobre os custos e a forma

Tabela 5.3: Estrutura e informação disponível na base de conhecimento

Nome da Tabela	Descrição
CBR AIRP	Lista de casos com causa AIRP
CBR ATC	Lista de casos com causa ATC
CBR COMM	Lista de casos com causa COMM
CBR CROT	Lista de casos com causa CROT
CBR HAND	Lista de casos com causa HAND
CBR INDUTY	Lista de casos com causa INDUTY
CBR MAINT	Lista de casos com causa MAINT
CBR METEO	Lista de casos com causa METEO
CBR OTHER	Lista de casos com causa OTH
CBR ROT	Lista de casos com causa ROT
CBR RULES	Lista de casos com causa RULES
CBR SEC	Lista de casos com causa SEC
CBR SIGN	Lista de casos com causa SIGN
CBR Solution Plan	Lista das soluções, para cada uma das dimensões, de cada um dos casos da base de conhecimento

como podem ser calculados podem ser encontrados em Castro (2013).

Para além destas informações, que já faziam parte do ambiente do sistema MASDIMA, foram usadas informações relativamente à base de conhecimento, essencial para a aplicação do *Case-based Reasoning* (tabela 5.3).

Tabela 5.4: Caracterização da informação do plano operacional de setembro de 2009

Característica	Descrição
Número de voos	7931
Voos com partida de LIS	3251 (41,0%)
Voos com partida de OPO	1026 (12,9%)
Voos com partida de FNC	356 (4,5%)
Voos com partida de FAO	105 (1,3%)
Voos com partida de outros aeroportos	3193 (40,3%)
Total bilhetes de passageiros disponíveis	1091964 lugares
Total bilhetes vendidos	585744 (53,6%)
Total aeronaves	39 <i>Narrow Body</i> (19 A319, 17 A320, 3 A321) 16 <i>Wide Body</i> (12 A330, 4 A340)
Total tripulantes	3028 (783 tripulação de voo, 2245 tripulação de cabine)
Por base operacional	2909 em LIS, 105 em OPO e 14 em FNC
Por categoria:	
Capitão (CPT)	414
Primeiro Oficial (OPT)	369
Comissário de Bordo Chefe	473
Comissário de Bordo	1641

Tabela 5.5: Caracterização dos problemas a resolver

Característica	Descrição
Voos afetados	49
Tipo de aeronaves afetadas	27 <i>Narrow Body</i> (14 A319, 10 A320, 3 A321) 4 <i>Wide Body</i> (3 A330, 1 A340)
Tripulantes afetados	286
Passageiros afetados	576 classe executiva, 4184 classe económica
Atraso total dos voos previsto	1752 min (média de 35,76 min por voo atrasado)
Custo total em aeronaves previsto	93800 u.m. (média de 1914,29 u.m. por voo atrasado)
Custo total em tripulação previsto	98843 u.m. (média de 2017,20 u.m. por voo atrasado)
Causas dos eventos	6 AIRP, 9 ATC, 2 COMM, 1 CROT 8 HAND, 1 INDUTY, 5 MAINT, 2 METEO 1 OTHER, 1 RULES, 5 SEC, 1 SIGN, 7 ROT

A tabela 5.4 caracteriza a informação do plano operacional de setembro de 2009. Como é possível observar, inclui informação extensa que é, na nossa opinião, suficientemente representativa e, por isso, pode ser utilizada nas nossas experiências.

Dos eventos mais representativos que ocorreram em setembro de 2009, selecionamos aleatoriamente quarenta e nove, que causaram igual número de problemas no plano operacional e que serão a nossa população de teste, isto é, os problemas a resolver nas experiências a realizar. A tabela 5.5 caracteriza os dados incluídos na tabela do ambiente *Eventos* (tabela 5.2), onde se pode consultar que estes eventos afetaram 49 voos, 31 aeronaves, 286 membros da tripulação e 4760 passageiros. No que diz respeito às causas dos eventos que causaram problemas, a distribuição, em percentagem, é semelhante à média anual.

A informação que utilizamos neste cenário é estática, isto é, não se altera durante as experiências que iremos realizar. Isto quer dizer que não existiram novos eventos a afetar os voos, para além daqueles que já caracterizamos. Todavia, na realidade, tal não sucede. Durante o processo de resolução de um problema, um novo evento pode afetar um dos recursos que está a ser considerado como possível solução para o problema, tornando-a inexecutável. Para tentar capturar esta dinâmica nas abordagens automáticas, limitamos o número de soluções candidatas geradas por cada agente e, aleatoriamente, forçamos a que em cada iteração uma parte das soluções geradas seja diferente. Isto é especialmente relevante no que diz respeito às abordagens que utilizam negociação automática com várias rondas.

É importante referir que o cenário construído é igual para todas as abordagens desenvolvidas, o que irá permitir compararmos as diferentes abordagens e tirarmos conclusões sobre as mesmas.

Construção da Base de Conhecimento

De forma a ser possível a utilização do método por nós proposto na secção 4.3, é necessário proceder previamente à construção da base de conhecimento, utilizada como ponto de partida na resolução dos problemas.

Selecionamos, para a construção da base de conhecimento, um segundo conjunto constituído por cento e noventa e seis novos problemas, caracterizados na tabela 5.6 e aleatoriamente escolhidos do plano operacional já descrito na tabela 5.4. Feita a escolha dos problemas a incorporar na base de conhecimento, estes foram resolvidos utilizando a abordagem **Q10-Best-V2** especificada na secção 3.2.10. A resolução destes cento e noventa e seis problemas, originou então a nossa base de conhecimento, que foi posteriormente trabalhada e armazenada nas estruturas referenciadas na tabela 5.3.

Tabela 5.6: Caracterização dos eventos utilizados para construção da Base de Conhecimento

Característica	Descrição
Voos afetados	196
Tipo de aeronaves afetadas	57 <i>Narrow Body</i> (21 A319, 19 A320, 3 A321, 2 BEH, 8 ER4, 4 F100) 16 <i>Wide Body</i> (12 A330, 4 A340)
Tripulantes afetados	1218
Passageiros afetados	2829 classe executiva, 26148 classe económica
Atraso total dos voos previsto	30990 min (média de 158,11 min por voo atrasado)
Custo total em aeronaves previsto	383150 u.m. (média de 1954,85 u.m. por voo atrasado)
Custo total em tripulação previsto	402291 u.m. (média de 2052,51 u.m. por voo atrasado)
Causas dos eventos	20 AIRP, 41 ATC, 8 COMM, 3 CROT 6 HAND, 5 INDUTY, 9 MAINT, 2 METEO 5 OTHER, 58 ROT, 2 RULES, 35 SEC, 2 SIGN

5.1.1 Métricas

Métricas ou indicadores de desempenho são essenciais para avaliar a experimentação e comparar diferentes abordagens utilizadas (ver 5.1.2 e 3.2).

Para melhor compreender as métricas que a seguir são definidas, é importante definir os conceitos de *experiência* e *execução*.

Definição 5.1.1. *Experiência*

Uma experiência corresponde a n execuções do sistema. Nas experiências realizadas neste trabalho definimos n com o valor 100.

Definição 5.1.2. *Execução*

Uma execução e consiste em resolver os quarenta e nove problemas caracterizados na secção 5.1 utilizando uma abordagem específica.

De forma a podermos comparar os resultados das novas abordagens por nós criadas, decidimos utilizar vinte e cinco métricas identificadas em Castro (2013), distribuídas da seguinte forma¹:

¹ Por uma questão de clareza na leitura deste documento, no anexo B pode ser consultada a definição destas métricas.

Experiências e Avaliação

- Treze do domínio do Transporte Aéreo:
 - Tempo Médio de Atraso dos Voos (*Average Flight Departure Delay* - definição B.1.1);
 - Tempo Médio de Atraso dos Tripulantes (*Average Crew Member Delay* - definição B.1.2);
 - Tempo Médio de Atraso da Viagem dos Passageiros (*Average Passenger Trip Time Delay* - definição B.1.3);
 - Custo Médio de Voo e Aeronave (*Average Flight and Aircraft Costs* - definição B.1.4);
 - Custo Médio com Tripulação (*Average Crew Costs* - definição B.1.5);
 - Custo Médio com Passageiros (*Average Passenger Costs* - definição B.1.6);
 - Rácio Médio de Recuperação dos Custos dos Voos (*Average Flight Cost Recovery Ratio* - definição B.1.7);
 - Rácio Médio de Recuperação dos Custos com Tripulação (*Average Crew Cost Recovery Ratio* - definição B.1.8);
 - Custo Médio de Voo por Minuto (*Average Flight Cost per Minute* - definição B.1.9);
 - Custo Médio com Tripulação por Minuto (*Average Crew Cost per Minute* - definição B.1.10);
 - Custo Médio com Passageiros por Minuto (*Average Passenger Cost per Minute* - definição B.1.11);
 - Número Médio de Voos com atraso superior a 15 minutos (*Average Number of Flights with Delay greater than 15 mins* - definição B.1.12);
 - Percentagem de Voos com atraso superior a 15 minutos (*Percentage of Flights with Delay greater than 15 mins* - definição B.1.13);
- Sete relacionadas com o Desempenho Negocial:
 - Utilidade Média Agente Supervisor (*Average Supervisor Agent Utility* - definição B.2.1);
 - Utilidade Média Agente *Manager* Avião (*Average Aircraft Agent Utility* - definição B.2.2);
 - Utilidade Média Agente *Manager* Tripulação (*Average Crew Agent Utility* - definição B.2.3);
 - Utilidade Média Agente *Manager* Passageiros (*Average Passenger Agent Utility* - definição B.2.4);
 - Utilidade Média de Bem-estar Social (*Average Utilitarian Social Welfare* - definição B.2.5);
 - Δ Médio para a Solução Ótima (*Average Δ to the Domain Optimal Solution* - definição B.2.6);
 - Equidade Global (*Global Fairness* - definição B.2.7);

- Cinco do domínio do Desempenho do Protocolo:
 - Número Médio de Rondas até atingir Acordo (*Average Number of Rounds to Reach an Agreement* - definição B.3.1);
 - Tempo Médio de Negociação (*Average Negotiation Time* - definição B.3.2);
 - Tempo Médio de Pesquisa (*Average Search Time* - definição B.3.3);
 - Número Médio de Mensagens Trocadas (*Average Number of Messages Exchanged* - definição B.3.4);
 - Número Médio de Mensagens por Problema (*Average Number of Messages per Problem* - definição B.3.5);

Para além destas, e para melhor podermos comparar as abordagens criadas, foram ainda definidas as seguintes métricas:

Definição 5.1.3. *Rácio Médio de Recuperação de Atrasos dos Voos*

A média do rácio de Recuperação de Atrasos dos Voos para uma experiência de n execuções e , é dada por:

$$\overline{FDrcv} = 1 - \frac{\sum_{e=1}^n \overline{FDrcv}_e}{n} \quad (5.1)$$

onde \overline{FDrcv}_e é a média aritmética do rácio de recuperação de atrasos de voos ($FDrcv$) de todos os voos incluídos na execução e . $FDrcv$ para um voo i é dado por:

$$FDrcv_i = \frac{FD_i}{OD_i} \quad (5.2)$$

onde FD_i é o atraso de um voo em minutos, de acordo com a equação B.1, e OD_i é o atraso original do voo do problema a ser resolvido.

Interpretação: Este rácio relaciona os minutos de atraso dos voos encontrados pela abordagem utilizada para realizar as execuções e com os minutos de atraso inicialmente previstos no problema utilizado na experiência. Quanto maior for o valor melhor. Um valor próximo de zero indica que a abordagem não foi capaz de recuperar os atrasos originais dos voos. Um valor próximo de um significa que a abordagem foi capaz de recuperar bem dos atrasos dos voos.

Definição 5.1.4. *Rácio Médio de Propostas Ganhas pelo Agente Manager Avião*

O rácio médio de propostas ganhas pelo agente *Manager Avião*, para uma experiência de n execuções e , é dado por:

$$\overline{ACwin} = \frac{\sum_{e=1}^n ACwin_e}{n} \quad (5.3)$$

onde $ACwin_e$ é o quociente entre o número de propostas ganhas, aqui referidas por vitórias, pelo agente *Manager* Avião ($ACwin$) e o número de casos a resolver de todos os voos incluídos na execução e . $ACwin_e$ é dado por:

$$ACwin = \frac{\text{vitórias}}{\text{casos}} \quad (5.4)$$

Interpretação: Este valor permite perceber se as propostas do agente *Manager* Avião têm, ou não, uma boa aceitação por parte do agente Supervisor. Isto é, conseguimos identificar em que medida este agente é capaz de fornecer propostas ao agente Supervisor que, em última instância, são as vencedoras da negociação.

Definição 5.1.5. *Rácio Médio de Propostas Ganhas pelo Agente Manager Tripulação*

O rácio médio de propostas ganhas pelo agente *Manager* Tripulação, para uma experiência de n execuções e , é dado por:

$$\overline{Cwin} = \frac{\sum_{e=1}^n Cwin_e}{n} \quad (5.5)$$

onde $Cwin_e$ é o quociente entre o número de propostas ganhas, aqui referidas por vitórias, pelo agente *Manager* Tripulação ($Cwin$) e o número de casos a resolver de todos os voos incluídos na execução e . $Cwin_e$ é dado por:

$$Cwin = \frac{\text{vitórias}}{\text{casos}} \quad (5.6)$$

Interpretação: Este valor permite perceber se as propostas do agente *Manager* Tripulação têm, ou não, uma boa aceitação por parte do agente Supervisor. Isto é, conseguimos identificar em que medida este agente é capaz de fornecer propostas ao agente Supervisor que, em última instância, são as vencedoras da negociação.

Definição 5.1.6. *Rácio Médio de Propostas Ganhas pelo Agente Manager Passageiros*

O rácio médio de propostas ganhas pelo agente *Manager* Passageiros, para uma experiência de n execuções e , é dado por:

$$\overline{PAXwin} = \frac{\sum_{e=1}^n PAXwin_e}{n} \quad (5.7)$$

onde $PAXwin_e$ é o quociente entre o número de propostas ganhas, aqui referidas por vitórias, pelo agente *Manager* Passageiros ($PAXwin$) e o número de casos a resolver de todos os voos incluídos na execução e . $PAXwin_e$ é dado por:

$$PAXwin = \frac{\text{vitórias}}{\text{casos}} \quad (5.8)$$

Interpretação: Este valor permite perceber se as propostas do agente *Manager* Passageiros têm, ou não, uma boa aceitação por parte do agente Supervisor. Isto é, conseguimos identificar em que medida este agente é capaz de fornecer propostas ao agente Supervisor que, em última instância, são as vencedoras da negociação.

5.1.2 Abordagens

Seguindo a mesma conduta utilizada por Castro (2013) para a realização das experiências foram consideradas múltiplas abordagens na resolução de problemas, uma manual e várias automáticas, a fim de ser possível estabelecer uma comparação entre elas.

No que diz respeito à abordagem manual, denominada de **TAP-AOC**, foram utilizados dados históricos fornecidos pela TAP Portugal. Sendo um processo manual, várias das métricas definidas não podem ser utilizadas, nomeadamente todas as métricas relacionadas com *Desempenho Negocial*. Mesmo no que diz respeito às métricas de *Transporte Aéreo*, algumas das métricas não puderam ser recolhidas porque a informação disponível não estava completa. Ainda assim, e uma vez que o cenário descrito é o mesmo para todas as abordagens, decidimos incluir a abordagem **TAP-AOC** porque nos permite retirar algumas ilações sobre como é que as abordagens automáticas se comportam face à prática manual.

O trabalho desta dissertação originou a criação de seis novas abordagens que foram adicionadas ao protótipo MASDIMA (capítulo 3). Segue-se uma descrição sumária de cada uma destas novas abordagens:

- **CBR10-Met-01** *CBR, máximo 10 soluções candidatas, sem restrições intermanager*: Esta abordagem consiste na utilização da técnica de CBR-DDE (secção 4.3) para a resolução de problemas nos AOCC. Aquando da receção, por parte dos agentes *manager*, do problema a resolver, acompanhado do caso mais semelhante presente na base de casos, cada agente *manager* irá forçar os seus agentes especialistas a utilizar a ação preconizada no caso mais semelhante, não impondo restrições aos restantes agentes *manager* na negociação entre *managers*. A solução a apresentar ao agente Supervisor, por cada agente *manager*, será escolhida com base na utilidade dada por cada *manager* (recorrendo às métricas B.2.2, B.2.3 e B.2.4, respetivamente) às soluções que tem à sua disponibilidade.

Caso o agente especialista não consiga gerar uma solução com a ação que lhe foi exigida, o agente *manager* irá fornecer-lhe outro caso, e o processo recomeçará. Se ao fim de três casos o agente especialista não conseguir encontrar uma solução, o problema é declarado como irresolúvel e é aceite o atraso por parte do sistema.

- **CBR10-Met-02** *CBR, máximo 10 soluções candidatas, com restrições intermanager*: Esta abordagem é semelhante à **CBR10-Met-01**, contudo, aquando da negociação entre *managers*, o *manager* que inicia a negociação impõe aos restantes que as soluções que lhe sejam apresentadas respeitem as ações presentes no caso mais semelhante.
- **CBR10-Met-03** *CBR, máximo 10 soluções candidatas, sem restrições intermanager, com penalização*: Esta abordagem é semelhante à **CBR10-Met-01**, contudo, na escolha da solução a apresentar ao agente Supervisor, cada agente *manager* escolherá, de entre as soluções que estão disponíveis, aquela que tiver maior valor de Bem-estar Social ($\overline{U_{sw}}$, B.2.5), após ter sido aplicada uma penalização (indicada no ficheiro de configuração do módulo de CBR) às dimensões que não respeitem as ações indicadas no caso mais semelhante.

- **CBR20-Met-01** *CBR, máximo 20 soluções candidatas, sem restrições intermanager*: Esta abordagem é muito semelhante à abordagem **CBR10-Met-01**, sendo a diferença o facto de existir um máximo de vinte soluções candidatas por agente *manager*, e não dez.
- **CBR20-Met-02** *CBR, máximo 20 soluções candidatas, com restrições intermanager*: Esta abordagem é muito semelhante à abordagem **CBR10-Met-02**, sendo a diferença o facto de existir um máximo de vinte soluções candidatas por agente *manager*, e não dez.
- **CBR20-Met-03** *CBR, máximo 20 soluções candidatas, sem restrições intermanager, com penalização*: Esta abordagem é muito semelhante à abordagem **CBR10-Met-03**, sendo a diferença o facto de existir um máximo de vinte soluções candidatas por agente *manager*, e não dez.

Os parâmetros e as equações utilizadas nas seis novas abordagens agora descritas podem ser consultados na tabela 5.7. O parâmetro *penalização* apenas é utilizado nas abordagens **CBR10Mod3** e **CBR20Mod3** e visa introduzir uma penalização, na função de utilidade dos agentes *manager*, caso a ação indicada pelo CBR não seja respeitada. As variáveis e os seus respetivos pesos foram escolhidos tendo em conta a opinião de especialistas da TAP Portugal e a nossa experiência durante o desenvolvimento destas abordagens. O ficheiro de configuração, tal como introduzido no sistema, pode ser consultado no anexo C.

Tabela 5.7: Equações e parâmetros utilizados nas novas abordagens

Parâmetros	Tipo	Peso	Valor
Número de casos mais semelhantes a considerar	inteiro	–	3
Penalização	real	–	0,5
Causa AIRP			
origin	texto	0,4	–
flight_number	texto	0,3	–
scheduled_time_of_departure	tempo (contínuo)	0,2	minutos, $\lambda = 0,5$
resource_type	texto	0,1	–
Causa ATC			
destination	texto	0,4	–
origin	texto	0,3	–
scheduled_time_of_arrival	tempo (contínuo)	0,2	minutos, $\lambda = 0,5$
flight_number	texto	0,1	–
Causa COMM			
flight_number	texto	0,4	–
scheduled_time_of_departure	tempo (contínuo)	0,3	minutos, $\lambda = 0,5$
origin	tempo (contínuo)	0,2	minutos, $\lambda = 0,5$
destination	texto	0,1	–
Causa CROT			
destination	texto	0,4	–
origin	texto	0,3	–
flight_number	texto	0,3	–

Continua na próxima página

Tabela 5.7: Equações e parâmetros utilizados nas novas abordagens

Parâmetros	Tipo	Peso	Valor
resource_type	texto	0,1	–
Causa HAND			
origin	texto	0,4	–
flight_number	texto	0,3	–
scheduled_time_of_departure	tempo (contínuo)	0,2	minutos, $\lambda = 0,5$
resource_type	texto	0,1	–
Causa INDUTY			
crew_res_type	texto	0,4	–
flight_number	texto	0,3	–
scheduled_time_of_departure	tempo (contínuo)	0,2	minutos, $\lambda = 0,5$
resource_type	texto	0,1	–
Causa MAINT			
resource_affected	texto	0,4	–
resource_type	texto	0,3	–
resource_cap	texto	0,2	–
origin	texto	0,1	–
Causa METEO			
origin	texto	0,4	–
scheduled_time_of_departure	tempo (contínuo)	0,3	minutos, $\lambda = 0,5$
scheduled_time_of_departure	tempo (periódico)	0,2	meses, $\lambda = 0,5$
resource_type	texto	0,1	–
Causa ROT			
flight_number	texto	0,4	–
origin	texto	0,3	–
resource_type	texto	0,2	–
destination	texto	0,1	–
Causa RULES			
flight_number	texto	0,4	–
scheduled_time_of_departure	tempo (contínuo)	0,3	minutos, $\lambda = 0,5$
origin	texto	0,2	–
destination	texto	0,1	–
Causa SEC			
resource_affected	texto	0,4	–
resource_type	texto	0,3	–
origin	texto	0,2	–
destination	texto	0,1	–
Causa SIGN			
flight_number	texto	0,4	–
scheduled_time_of_departure	tempo (contínuo)	0,3	minutos, $\lambda = 0,5$
origin	texto	0,2	–
destination	texto	0,1	–
Causa OTHER			
flight_number	texto	0,125	–
scheduled_time_of_departure	tempo (contínuo)	0,125	minutos, $\lambda = 0,5$
origin	texto	0,125	–
destination	texto	0,125	–

Continua na próxima página

Tabela 5.7: Equações e parâmetros utilizados nas novas abordagens

Parâmetros	Tipo	Peso	Valor
resource_affected	texto	0,125	–
resource_type	texto	0,125	–
crew_res_type	texto	0,125	–
scheduled_time_of_arrival	tempo (contínuo)	0,125	minutos, $\lambda = 0,5$

Tabela 5.8: Equações e parâmetros utilizados nas abordagens já existentes (secção 3.2) (Castro, 2013)

Parâmetros/Equações	Valores
(T) Temperatura:	12
(α) Taxa de Aprendizagem:	0,9 ($\beta = 0,05$)
(γ) Fator de Desconto:	0,6
Q-Value na fórmula de atualização do Q-Learning	$Q(st, at) = Q(st, at) + \alpha(rw + \gamma \max_a Q(st*, a) - Q(st, at))$
Fórmula de Exploração de Boltzmann	$p(a) = \frac{e^{Q(s,a)/t}}{\sum_{b \in AT} e^{Q(s,b)/t}}$, com $t > 0; b, a \in AT; s \in ST$
Q-Value na fórmula de atualização do SARSA	$Q(st, at) = Q(st, at) + \alpha(rw + \gamma Q(st*, a) - Q(st, at))$

As equações e os parâmetros utilizados nas abordagens já existentes no MASDIMA (ver secção 3.2) podem ser consultados na tabela 5.8. Os valores utilizados foram os mesmos de Castro (2013), de forma a ser possível utilizar os dados do autor para comparar com as novas abordagens.

Na tabela 5.9 encontram-se os pesos e os parâmetros utilizados nas funções de avaliação dos agentes Supervisor, *Manager* Avião, *Manager* Tripulação e *Manager* Passageiros. Estes valores foram utilizados tanto para as novas abordagens, baseadas em CBR, aqui definidas, como para as abordagens já existentes no MASDIMA.

Tabela 5.9: Pesos e parâmetros para as funções de utilidades dos agentes (equações 3.4, 3.1, 3.2 e 3.3)

Agente	Valores
Agente Supervisor	
Pesos	$\alpha_{1,2,3} = 1; w_1 = 1; w_2 = 0,33; w_3 = 0,66;$ $w_4 = 0,11; w_5 = 0,11; w_6 = 0,11$
Valores Preferenciais	Atraso avião e tripulação: 0 Atraso viagem do passageiro: 0 Custo avião e tripulação: 1,05 * custo inicialmente previsto Custo passageiros: 10 * número total passageiros
Valores Máximos	Atrasos avião, tripulação e passageiros: 120 Custo avião e tripulação: 1,5 * custo inicialmente previsto Custo passageiros: 100 * número total passageiros
Agente Manager Avião	
Pesos	$v_1 = 1; v_2 = 0,11;$
Valores Máximos	Atrasos avião, tripulação e passageiros: 120 Custo avião: 4400 u.m. Custo tripulação: 3500 u.m. Custo passageiros: 9800 u.m.
Agente Manager Tripulação	
Pesos	$v_1 = 0,33; v_2 = 0,11;$
Valores Máximos	Atrasos avião, tripulação e passageiros: 120 Custo avião: 4400 u.m. Custo tripulação: 3500 u.m. Custo passageiros: 9800 u.m.
Agente Manager Passageiros	
Pesos	$v_1 = 0,66; v_2 = 0,11;$
Valores Máximos	Atrasos avião, tripulação e passageiros: 120 Custo avião: 4400 u.m. Custo tripulação: 3500 u.m. Custo passageiros: 9800 u.m.

5.2 Análise de Resultados

Nesta secção decidimos incluir, para além dos resultados das experiências às abordagens definidas na secção anterior, os resultados da abordagem utilizada pela TAP Portugal, aqui denominada **TAP-AOC**, e de algumas das abordagens já existentes no sistema MASDIMA, nomeadamente as abordagens **TSA**, **GQN10-Best-V2** e **GQN20-Best-V2** (secção 3.2). A escolha da abordagem **TSA** deve-se às suas características, únicas no sistema MASDIMA, por não consistir num processo baseado em rondas, enquanto que a escolha das abordagens **GQN10-Best-V2** e **GQN20-Best-V2** se deveu ao facto de estas, de todas as preexistentes no sistema MASDIMA, serem as que apresentavam melhores resultados.

Experiências e Avaliação

Os resultados das experimentações realizadas podem ser encontrados nas tabelas 5.10, 5.11 e 5.12, que se seguem.

Tabela 5.10: Resultados das abordagens TAP-AOC, TSA, Q10-Best-V2 e Q20-Best-V2

Métrica	TAP-AOC	TSA	Q10-Best-V2	Q20-Best-V2
<i>Transporte Aéreo</i>				
\overline{FD} (min)	36,05	6,15	3,56	2,95
\overline{CwD} (min)	–	4,75	10,76	7,75
\overline{PD} (min)	41,00	28,25	4,76	3,52
\overline{FC} (u.m.)	2081	1967	1273	1006
\overline{CC} (u.m.)	2158	1094	1075	619
\overline{PC} (u.m.)	–	2825	1709	1463
\overline{FDrcv} (ratio)	0,831	0,220	0,124	0,110
\overline{FCrcv} (ratio)	1,087	1,028	0,714	0,583
\overline{CCrcv} (ratio)	1,070	0,944	0,583	0,315
\overline{FCmin} (u.m. por minuto)	47,949	45,315	35,594	28,149
\overline{CCmin} (u.m. por minuto)	49,274	43,862	30,076	17,310
\overline{PCmin} (u.m. por minuto)	–	65,092	47,807	40,913
$\overline{FD15min}$ (#)	18	2,5	0,3	0,0
$p(\overline{FCmin})$ (%)	36,73	5,1	0,7	0,0
<i>Desempenho Negocial</i>				
$\overline{Usup}[0, 1]$	–	0,726	0,917	0,938
$\overline{Ua/c}[0, 1]$	–	0,9	0,945	0,955
$\overline{Ucrew}[0, 1]$	–	0,869	0,859	0,908
$\overline{Upax}[0, 1]$	–	0,682	0,941	0,953
$\overline{Usw}[0, 1]$	–	2,451	2,745	2,816
$\Delta(optimal)[0, 1]$	–	0,130	0,020	-0,001
$\overline{GF}(var)$	–	0,009	0,002	0,000
$\overline{ACwin}[0, 1]$	–	–	–	–
$\overline{Cwin}[0, 1]$	–	–	–	–
$\overline{PAXwin}[0, 1]$	–	–	–	–
<i>Desempenho do Protocolo</i>				
\overline{NR} (#)	–	–	4,98	5,37
\overline{NT} (sec)	–	–	0,64	0,64
\overline{ST} (sec)	–	51,00	0,05	0,05
\overline{Msg} (#)	–	760	23532	23569
\overline{Mprb} (msg por problema)	–	38,00	480,25	481,00

Tabela 5.11: Resultados das abordagens CBR10-Met-01, CBR10-Met-02 e CBR10-Met-03

Métrica	CBR10-Met-01	CBR10-Met-02	CBR10-Met-03
<i>Transporte Aéreo</i>			
\overline{FD} (min)	6,35	6,71	7,09
\overline{CwD} (min)	13,25	12,20	14,06
\overline{PD} (min)	8,86	6,99	7,82
\overline{FC} (u.m.)	1830	1803	1824
\overline{CC} (u.m.)	1257	1476	1286
\overline{PC} (u.m.)	2284	2305	2061
\overline{FDrcv} (ratio)	0,253	0,246	0,258
\overline{FCrcv} (ratio)	1,034	0,978	1,049
\overline{CCrcv} (ratio)	0,685	0,787	0,681
\overline{FCmin} (u.m. por minuto)	51,169	50,423	51,018
\overline{CCmin} (u.m. por minuto)	35,167	41,286	35,984
\overline{PCmin} (u.m. por minuto)	63,876	64,469	57,632
$\overline{FD15min}$ (#)	5,3	3,7	6,0
$p(\overline{FCmin})$ (%)	0,109	0,075	0,122
<i>Desempenho Negocial</i>			
$\overline{Usup}[0, 1]$	0,882	0,884	0,881
$\overline{Ua/c}[0, 1]$	0,912	0,909	0,906
$\overline{Ucrew}[0, 1]$	0,830	0,824	0,824
$\overline{Upax}[0, 1]$	0,902	0,917	0,914
$\overline{Usw}[0, 1]$	2,816	2,649	2,644
$\Delta(\overline{optimal})[0, 1]$	0,055	0,053	0,055
$\overline{GF}(var)$	-0,094	-0,083	0,005
$\overline{ACwin}[0, 1]$	0,360	0,354	0,320
$\overline{Cwin}[0, 1]$	0,347	0,387	0,279
$\overline{PAXwin}[0, 1]$	0,293	0,259	0,401
<i>Desempenho do Protocolo</i>			
\overline{NR} (#)	1	1	1
\overline{NT} (sec)	0,79	0,82	0,36
\overline{ST} (sec)	0,58	0,67	0,28
\overline{Msg} (#)	3283	3283	3283
\overline{Mprb} (msg por problema)	67,00	67,00	67,00

Tabela 5.12: Resultados das abordagens CBR20-Met-01, CBR20-Met-02 e CBR20-Met-03

Métrica	CBR20-Met-01	CBR20-Met-02	CBR20-Met-03
<i>Transporte Aéreo</i>			
\overline{FD} (min)	4,03	4,76	4,27
\overline{CwD} (min)	8,87	8,88	9,56
\overline{PD} (min)	5,19	5,44	5,29
\overline{FC} (u.m.)	1516	1383	1424
\overline{CC} (u.m.)	921	1005	994
\overline{PC} (u.m.)	1852	1758	1685
\overline{FDrcv} (ratio)	0,151	0,162	0,166
\overline{FCrcv} (ratio)	0,849	0,781	0,822
\overline{CCrcv} (ratio)	0,482	0,527	0,530
\overline{FCmin} (u.m. por minuto)	42,398	38,690	39,835
\overline{CCmin} (u.m. por minuto)	25,753	28,118	27,792
\overline{PCmin} (u.m. por minuto)	51,786	49,171	47,126
$\overline{FD15min}$ (#)	1,3	1,3	1,3
$p(\overline{FCmin})$ (%)	0,027	0,027	0,027
<i>Desempenho Negocial</i>			
$\overline{Usup}[0, 1]$	0,914	0,912	0,913
$\overline{Ua/c}[0, 1]$	0,936	0,932	0,936
$\overline{Ucrew}[0, 1]$	0,881	0,875	0,871
$\overline{Upax}[0, 1]$	0,936	0,936	0,938
$\overline{Usw}[0, 1]$	2,753	2,742	2,745
$\overline{\Delta(optimal)}[0, 1]$	0,023	0,025	0,024
$\overline{GF}(var)$	0,004	-0,076	-0,064
$\overline{ACwin}[0, 1]$	0,265	0,354	0,327
$\overline{Cwin}[0, 1]$	0,401	0,326	0,367
$\overline{PAXwin}[0, 1]$	0,334	0,320	0,306
<i>Desempenho do Protocolo</i>			
\overline{NR} (#)	1	1	1
\overline{NT} (sec)	0,36	0,36	0,40
\overline{ST} (sec)	0,29	0,28	0,31
\overline{Msg} (#)	3283	3283	3283
\overline{Mprb} (msg por problema)	67,00	67,00	67,00

A análise dos resultados da nossa experimentação visa responder às seguintes questões:

Q1 As propostas baseadas nas abordagens que usam CBR-DDE (a proposta deste trabalho) são melhores que a tradicional (TSA)?

Q2 Como se comparam as abordagens preexistentes no sistema MASDIMA com as novas abordagens baseadas em CBR, no que diz respeito à utilidade das soluções?

Q3 Há causas de eventos onde o CBR apresenta melhores resultados que as abordagens que utilizam GQN?

Q4 Existem benefícios, do ponto de vista económico, na aplicação das abordagens propostas baseadas em CBR?

Q5 Qual é o impacto do valor da função de semelhança na qualidade das soluções apresentadas?

Q6 Qual das novas abordagens CBR-DDE permite obter soluções com utilidade mais elevada?

Q7 Do ponto de vista do desempenho do protocolo, há diferenças entre as abordagens baseadas em CBR e as baseadas em GQN?

Relativamente à **primeira questão**, podemos dizer que as abordagens baseadas em CBR-DDE são, tipicamente, superiores à abordagem *TSA*. Todavia há algumas métricas em que esta última apresenta um melhor desempenho. Por exemplo, olhando para o *Rácio Médio de Recuperação de Atrasos à Partida Voos* (\overline{FDrcv}) (figura 5.1), é possível observar que a abordagem *TSA* tem melhores resultados, ainda que marginais, do que em algumas das abordagens CBR-DDE. Contudo, estes resultados só são possíveis graças a um *Custo Médio com Passageiros* (\overline{PC}) (figura 5.2) e *Custo Médio com Tripulação* (\overline{CC}) (figura 5.3) superiores. Isto pode ser explicado pela natureza da conceção da abordagem *TSA*, que inicia a pesquisa por soluções resolvendo em primeiro lugar a dimensão avião e só depois as dimensões tripulação e passageiros. De um ponto de vista global, analisando as utilidades dos agentes que representam todas as partes do problema bem como a distância média das soluções encontradas às respetivas soluções ótimas, podemos concluir que as abordagens por nós propostas são superiores à abordagem tradicional (figuras 5.4, 5.5).

Respondendo à **segunda questão**, as novas abordagens apresentam um comportamento misto em relação à utilidade das soluções, face a todas as abordagens preexistentes no sistema MASDIMA. Se nos reportarmos apenas às duas abordagens que obtêm melhores desempenhos (**GQN10-Best-V2** e **GQN20-Best-V2**), então podemos verificar que, no geral, a utilidade das soluções propostas por estas duas abordagens são superiores às apresentadas pelas abordagens baseadas em CBR (figura 5.4). Contudo, não é possível afirmar, categoricamente, que a utilidade das soluções propostas pelas abordagens baseadas em CBR seja sempre inferior às abordagens preexistentes no MASDIMA. Na realidade devemos analisar esta questão sobre duas perspetivas:

Experiências e Avaliação




Figura 5.1: Rácio Médio de Recuperação de Atrasos à Partida dos Voos (\overline{FDrcv})




Figura 5.2: Custo Médio com Passageiros (\overline{PC})

Experiências e Avaliação




Figura 5.3: Custo Médio com Tripulação (\overline{CC})




Figura 5.4: Utilidades dos Agentes e $\Delta(\text{optimal})$




Figura 5.5: Média de Bem-estar Social ($\overline{U_{sw}}$)

1. Por uma questão de simplificação na apresentação dos resultados das experiências efetuadas, optamos por apenas comparar aquelas, de entre as já existentes, que apresentam melhores resultados, **Q10-Best-V2** (3.2.10) e **Q20-Best-V2** (3.2.11). Note-se que muitas das restantes abordagens apresentavam valores de utilidade e bem-estar social inferiores aos que obtivemos nas novas abordagens;
2. Sob a perspetiva da utilidade das soluções, o facto de, em média, as soluções das abordagens *GQN* serem superiores (figura 5.4) era algo por nós esperado e que faz sentido. Nas atuais abordagens *GQN*, a cada ronda de negociação os agentes especialistas dos *managers* que perderam a ronda geram novas soluções candidatas. Isto leva a que, no fim da negociação, tenha sido gerado um número de soluções candidatas consideráveis fazendo com que se escolha a melhor solução deste enorme conjunto de soluções candidatas. Pelo contrário, as abordagens por nós propostas utilizam apenas uma ronda, o que faz com que o número de soluções candidatas gerado seja muito inferior. Ainda assim, e apesar desta redução drástica do número de soluções candidatas disponíveis, o valor médio da utilidade para o Supervisor ($\overline{U_{sup}}$) e agentes *manager* ($\overline{U_{a/c}}$, $\overline{U_{crew}}$ e $\overline{U_{pax}}$), das soluções apresentadas pelas nossas abordagens, não se distancia muito daquele apresentado pelas abordagens *GQN*, havendo inclusivamente momentos em que as nossas abordagens mostram um desempenho superior às abordagens *GQN*, como iremos analisar em mais detalhe na resposta à terceira questão.

Estes resultados mostram que, apesar de à primeira vista parecer que as abordagens *GQN* são superiores em tudo o que diz respeito à utilidade das soluções apresentadas, de facto,

olhando para a figura 5.6, podemos verificar que dentro do nosso cenário com 49 casos, e quando comparando cada uma das nossas abordagens com as abordagens *GQN*, houve efetivamente problemas que foram melhor resolvidos com as nossas abordagens do que com as *GQN*, apesar de ser inegável que, em média, as abordagens *GQN* apresentam uma menor distância ao planeamento inicialmente efetuado ($\Delta(optimal)$) e melhores resultados no que diz respeito à utilidade das soluções para o agente Supervisor ($\overline{U_{sup}}$).

Analisando atentamente a figura 5.6 podemos observar um padrão interessante, especialmente nos gráficos onde comparamos a abordagem **Q10-Best-V2** com as por nós desenvolvidas (lado esquerdo), onde se percebe que o agente *Manager* Tripulação, dos quatro agentes ali representados, é aquele que apresenta um maior número de problemas onde tem utilidades superiores às dos seus homólogos na abordagem **Q10-Best-V2**. Na nossa opinião isto deve-se ao facto desta dimensão ser aquela que apresenta um maior número de ações possíveis para serem usadas na resolução de problemas (tabela 4.5). Como os agentes especialistas apenas estão a apresentar no máximo dez soluções candidatas de cada dimensão, as opções dadas são mais diversificadas, não sendo testadas várias combinações com a mesma ação. Nas nossas abordagens, por outro lado, ao direcionarmos os agentes especialistas para determinada ação, eles vão gerar as dez soluções candidatas com a mesma ação, testando várias combinações e levando, potencialmente, a melhores resultados. Ao passarmos para as abordagens com vinte soluções candidatas esta diferença esbate-se um pouco, como seria de esperar.

Respondendo à **terceira questão**, o comportamento das abordagens baseadas em CBR não é uniforme no que diz respeito à utilidade das soluções propostas em função da causa que originou o problema. A título de exemplo, observando a figura 5.7, é possível verificar que nas causas COMM, MAINT, SIGN, INDUTY, ROT, SEC e OTHER, a utilidade do agente *Manager* Tripulação é superior à do seu homólogo na melhor abordagem *GQN* com o mesmo número de soluções candidatas máximo.

Do nosso ponto de vista, o mesmo ocorre devido a diversos fatores. Por um lado, a qualidade da base de casos tem um peso relevante e é um fator a ter em conta. Havendo casos mais semelhantes na base de casos e tendo esses casos boas soluções, isso será refletido nas soluções propostas por estas abordagens. Por outro lado, o número de ações disponíveis em cada uma das dimensões é também de ter em conta, uma vez que atualmente os agentes especialistas estão a gerar um número fixo de soluções aleatórias, com base no conjunto de recursos definido e, por isso, havendo poucas ações, eles estão a explorá-las a um nível razoável. Quando o número de ações aumenta (caso da dimensão tripulação), a indicação da ação a executar permite explorá-la de forma mais exaustiva, aumentando, potencialmente, a hipótese de obtermos uma melhor solução.

A figura 5.8 fornece-nos a resposta à **quarta questão**. Como referido em Castro (2013), estudos mostram que as operações irregulares podem custar entre 2% e 3% das receitas anuais das companhias aéreas e que um melhor processo de recuperação das roturas pode resultar numa redução de custos em, pelo menos, 20%. Considerando o caso específico da TAP Portugal e

Experiências e Avaliação




Figura 5.6: Número de Casos onde as Abordagens CBR-DDE são superiores por Métrica Desempenho Negocial




Figura 5.7: Utilidade Média do Agente Tripulação ($\overline{U_{crew}}$) por Causa de Evento

de acordo com o plano anual de 2010, a receita anual situou-se nos €1.986,3M. As operações irregulares podem ter custado entre €39,7M e €59,5M.

Com base nestes valores, calculamos que as abordagens **CBR10-*** apresentam uma redução potencial de custos média entre os 18,26% e os 20,45%, e as abordagens **CBR20-*** entre 37,41% e 39,46%. Isto traduz-se, para o caso da TAP Portugal, em poupanças anuais entre €9,06M e €19,57M (figura 5.9).

A figura 5.10 fornece-nos a resposta à **quinta questão**. De facto é possível observar que quanto maior o grau de similitude entre o problema a resolver e o caso mais semelhante na base de casos, maior a utilidade média para o agente Supervisor. Estes dados permitem-nos ainda afirmar que a função de similitude utilizada (equação 4.1) se encontra, no essencial, bem definida.

Através dos dados recolhidos não é possível dar uma resposta conclusiva à **sexta questão**. Como é possível verificar nos gráficos apresentados, nenhuma das abordagens CBR-DDE se mostra particularmente superior às suas congéneres em termos de utilidade (ver resposta a **Q6**). Esta questão deve ser essencialmente percecionada do ponto de vista da confiabilidade do sistema. Um dos objetivos que nos propusemos atingir foi o de fornecer alternativas nas quais fosse reconhecido um grau de confiabilidade elevado (secção 1.2). Na realidade, As abordagens **CBR10-Met-02** e **CBR20-Met-02**, fazem com que o sistema adote sempre ações que já foram previamente realizadas, visto serem provenientes da base de conhecimento, e não ser dada liberdade aos agentes especialistas para gerarem soluções com ações distintas. Daqui resulta que, se a base de conhecimento tiver sido criada com as preferências e crenças de utilizadores humanos, o sistema produzirá

Experiências e Avaliação




Figura 5.8: Percentagem de (possível) Redução de Custo




Figura 5.9: Possível redução de custos para a TAP Portugal




Figura 5.10: Utilidade Média Agente Supervisor (\overline{Usup}) em função da Similitude do caso mais semelhante

sempre soluções que utilizam o mesmo tipo de ações, fazendo com que este tenha um comportamento mais semelhante àquele que lhe foi ensinado, do que nas restantes abordagens.

Assim, podemos dizer que se o objetivo for introduzir um sistema automático para resolução de roturas nos planos de voo, mas que ao mesmo tempo possa ter a confiança daqueles que o supervisionam, as abordagens **CBR10-Met-02** e **CBR20-Met-02** irão, provavelmente, ser aquelas que apresentam soluções que, à primeira vista, são aceitáveis para os controladores humanos (o que não implica que sejam as melhores).

Respondendo à **sétima questão**, na perspetiva da eficiência do protocolo de negociação, isto é, número de mensagens trocadas entre agentes e recursos despendidos em comunicação, e desempenho em termos temporal global, as abordagens aqui propostas são em tudo superiores às abordagens *GQN*, como demonstram as figuras 5.11 e 5.12. Com menos, aproximadamente, 86% de mensagens trocadas, e apenas uma ronda de negociação, as abordagens por nós desenvolvidas apresentam-se mais céleres na resolução de problemas, cumprindo um dos objetivos definidos no início deste relatório (secção 1.2).

Do ponto de vista temporal, as novas abordagens propostas representam uma redução de 64% nos testes por nós realizados, como mostra a figura 5.13.

É ainda de salientar que as abordagens definidas apresentam uma complexidade temporal para cada problema de $O(1)$, enquanto que as abordagens *GQN* apresentam uma complexidade $O(n)$, sendo n o número de rondas necessárias para atingir acordo. Neste momento os agentes espe-

cialistas estão a gerar soluções aleatórias com base num conjunto restrito de recursos, mas caso a complexidade destes agentes aumente e, consequentemente, o seu tempo de execução, esta diferença pode tornar as abordagens *GQN* inutilizáveis em circunstâncias que exijam uma solução para um problema num reduzido espaço de tempo.




Figura 5.11: Número Médio de Mensagens por Problema (\overline{Mprb})




Figura 5.12: Número Médio de Rondas por Problema (\overline{NR})




Figura 5.13: Tempo por Abordagem

5.3 Resumo

Neste capítulo foram apresentadas as experiências que planeamos e os resultados obtidos. Começamos por introduzir o cenário preparado, incluindo a caracterização da informação usada e dos problemas a resolver, definimos as métricas a utilizar e explicamos as novas abordagens utilizadas para resolver os problemas. Das diversas abordagens já existentes no sistema MASDIMA (ver secção 3.2) escolhemos aquelas que apresentam melhores resultados, como abordagens de comparação para os novos métodos introduzidos nesta dissertação.

Dos resultados apresentados e da discussão que se seguiu, as principais conclusões que retiramos são:

- As abordagens propostas são superiores, em geral, à abordagem tradicional (TSA) e melhores que o processo manual desenvolvido no CCO da TAP Portugal;
- Em situações onde o tempo para resolver um problema seja escasso, as abordagens CBR-DDE são as mais indicadas visto que apresentam tempos de resolução muito inferiores aos das abordagens *GQN*. Uma redução de 64% do tempo de resolução, face às abordagens *GQN*, apenas faz diminuir, em média, a utilidade das soluções em 3%.
- Há certas causas de eventos onde as abordagens CBR-DDE desenvolvidas têm melhores resultados que as abordagens *GQN*;
- A qualidade e diversidade da base de conhecimento tem influência no desempenho das abordagens introduzidas. Como seria de esperar, se a base de conhecimento for mais extensa e contiver uma maior diversidade de casos é expectável que se encontrem casos mais similares aos novos problemas, e que, consequentemente, o desempenho da metodologia aumente;
- Não é possível dizer taxativamente que, das novas abordagens apresentadas, alguma é melhor que as restantes. Todas apresentam resultados semelhantes, sendo que apenas se pode preferir uma a outra por uma questão de confiabilidade do sistema;
- Apesar de na globalidade as abordagens *GQN* apresentarem melhores resultados, há situações onde as novas abordagens baseadas em CBR apresentam utilidades superiores às obtidas pelas abordagens *GQN*;

Capítulo 6

Conclusão

Neste capítulo concluímos a apresentação do trabalho realizado no âmbito desta dissertação, recordando o contexto e motivação, verificando o cumprimento dos objetivos, as contribuições científicas efetuadas e o trabalho futuro que pode ser realizado para refinar e pôr em prática o trabalho que aqui foi apresentado.

6.1 Visão Geral

Nesta dissertação analisamos o problema da introdução da aprendizagem com o passado no apoio à negociação automática nos Centros de Controlo Operacional de Companhias Aéreas, nomeadamente através da criação de um módulo de aprendizagem com o passado no sistema MASDIMA (*Multi-Agent System for Disruption Management*). Este módulo tem como principal objetivo reduzir o tempo decorrido desde que um problema é identificado pelo sistema até que é encontrada uma solução aceite pelo agente Supervisor.

Para resolver este problema analisamos em detalhe a metodologia *Case-based Reasoning* (CBR), uma vez que o seu conceito, tal como introduzido em Aamodt e Plaza (1994), traduz precisamente aquilo que procuramos. Após uma revisão cuidada da literatura sobre CBR e projetos que implementaram a metodologia, rapidamente nos apercebemos que, apesar do ciclo CBR (figura 2.1) contemplar as fases de reutilização e adaptação de casos, na prática estas nunca chegam a ser implementadas na maioria dos projetos por nós analisados.

Em ambientes dinâmicos onde duas soluções raramente se repetem, como é o caso da gestão de roturas nos planos operacionais da aviação civil, a aplicação de uma metodologia como CBR foi algo até agora pouco explorado. Tal deveu-se, na nossa opinião, à dificuldade de reutilização e adaptação de soluções passadas, uma vez que estas se tornam rapidamente obsoletas.

Após a análise da estrutura do protótipo MASDIMA e depois de conhecidas as abordagens preexistentes no sistema, partimos para a formalização do problema a resolver e para a conceptualização da metodologia a aplicar.

Do conhecimento da metodologia CBR e dos sistemas multiagente, da análise das abordagens existentes e das características da gestão de roturas dos planos operacionais das companhias

aéreas, nasceu a metodologia CBR-DDE (*Case-based Reasoning - Distributed for Dynamic Environments*).

O CBR-DDE foi criado com o intuito de aproveitar as sinergias resultantes da fusão do conceito de sistemas multiagente com a metodologia CBR. Através desta fusão e distribuição das várias fases do ciclo CBR por entidades distintas, foi possível ultrapassar o conceito de adaptação em CBR, utilizado nas aplicações comerciais analisadas, aproximando-o da sua génese e expandindo a noção atual de adaptação.

A noção de adaptação frequentemente encontrada na literatura (Hammond, 1990; Kolodner, 1993; Smyth e Keane, 1998) refere-se à criação de uma nova solução através da alteração parcial de uma solução existente na base de conhecimento. A nossa abordagem apresenta uma visão distinta, sendo que, para nós, adaptação é reaproveitar o raciocínio de resolução subjacente à solução do caso mais semelhante da base de conhecimento mas, em vez de tentarmos adaptar algo que não foi gerado tendo em conta o estado atual do ambiente, geramos uma nova solução, integralmente original e por isso adaptada às restrições atuais do ambiente e que segue a mesma linha de ação da solução utilizada no passado.

A nova forma de adaptação descrita, aliada à implementação da metodologia CBR num sistema multiagente, permitiu-nos capitalizar as sinergias desta fusão e equipar o protótipo com abordagens que lhe permitem gerar soluções meritórias num curto espaço de tempo.

6.2 Verificação dos Objetivos

Num ambiente dinâmico e codependente como o da gestão de roturas nos planos de voo das companhias aéreas, onde um atraso pode desencadear um conjunto de roturas por todo o sistema, o tempo de resolução destes problemas é crítico. Se o sistema não for capaz de responder em tempo útil, pode dar-se o caso de a solução encontrada não ser mais exequível quando apresentada, o que torna todo o sistema ineficaz.

Da necessidade de dotar o sistema MASDIMA da capacidade de fornecer soluções para as roturas num curto espaço de tempo surge o principal objetivo desta dissertação, como enunciado na secção 1.2. Na avaliação feita às experiências realizadas (capítulo 5), podemos verificar que foi possível reduzir o tempo médio de resposta do sistema a um novo problema em cerca de 64%, aumentando, simultaneamente, o seu grau de confiabilidade e limitando a perda de utilidade das soluções, aferida pelo agente Supervisor. Esta nova metodologia fornece, inclusivamente, em alguns casos, soluções superiores às das melhores abordagens já existentes no sistema MASDIMA.

Ao gerarmos soluções baseadas em conhecimento do passado, que pode ser introduzido no sistema por operadores humanos, ensinamos o protótipo a produzir soluções que seguem a linha de raciocínio desse conhecimento. Isto faz com que as soluções geradas pelas abordagens baseadas em CBR, numa primeira análise, sejam familiares aos operadores humanos presentes nos Centros de Controlo Operacional, aumentando o grau de confiança no sistema.

Acreditamos ainda que quando o sistema for colocado em funcionamento, e a sua base de conhecimento alargada com os casos do plano operacional de um ano completo, a qualidade e

desempenho das abordagens baseadas em CBR pode aumentar substancialmente, como indicam os dados das nossas experiências, traduzidos na figura 5.10.

6.3 Contribuições Científicas

Nesta secção iremos recapitular as principais contribuições científicas alcançadas com o trabalho desta dissertação e já descritas na secção 1.3.

Do trabalho realizado, para permitir a verificação dos objetivos, podemos retirar algumas contribuições científicas, das quais destacamos as seguintes:

- A criação de uma nova metodologia, baseada em CBR, que permite a reutilização e adaptação de soluções em sistemas que trabalham sobre ambientes dinâmicos. Entendemos que a metodologia CBR-DDE (secção 4.3) mostrou ser aplicável ao problema da gestão de roturas nos CCO, mas está formalizada a um nível suficiente de abstração que permitirá a sua instanciación em aplicações noutros domínios;
- A introdução de *Case-based Reasoning* como técnica de resolução de problemas na gestão de roturas nos Centros de Controlo Operacional de Companhias Aéreas, que permitiu a diminuição do tempo necessário para a geração de uma solução meritória nos CCO;
- A abordagem distribuída do CBR (secção 4.3), através da cooperação entre agentes, que apesar de já estar presente em outros projetos, nunca tinha sido efetuada no âmbito da gestão de roturas nos CCO;
- Um método de comparação de roturas nos planos operacionais das companhias aéreas (secção 4.1.2), que permite aferir a sua semelhança e que poderá ser utilizado noutros projetos dentro deste âmbito.

6.4 Limitações e Trabalho Futuro

As principais limitações deste trabalho prendem-se com as limitações do próprio protótipo MASDIMA, descritas em Castro (2013), e dizem respeito ao cenário de simulação como já referido na secção 5.1.

O ramo do transporte aéreo tem comportamentos sazonais pelo que idealmente deveríamos incluir no cenário de teste dados de um plano operacional anual completo. Contudo, pela enorme quantidade de dados que um plano operacional completo compreende e por forma a podermos comparar as novas abordagens com as já existentes no protótipo, optamos por nos cingir ao cenário descrito no capítulo 5.

A simulação da dinâmica do ambiente é outra das limitações do protótipo MASDIMA. Num dia de operação real a informação não é estática, isto é, pode haver alterações durante o processo de recuperação de uma rotura. Para tentar minimizar esta limitação foi reduzido o número de soluções candidatas possíveis, entre 10 e 20 dependendo da abordagem utilizada.

Conclusão

Em relação ao trabalho futuro, é nosso objetivo submeter um artigo para a **XXXIV ICCBR**¹ (*International Conference on Case-Based Reasoning*), intitulado *Case-based Reasoning - Distributed for Dynamic Environments*, demonstrando as capacidades da metodologia CBR-DDE.

Do trabalho realizado nesta dissertação entendemos que poderão surgir novos interesses de pesquisa nesta área, nomeadamente na procura de uma metodologia que englobe o melhor das abordagens GQN e CBR numa única abordagem, melhorando a prestação global do sistema. A constante variação da base de conhecimento, expectável com a entrada em funcionamento do sistema, irá originar a criação de *sub-clusters* dinâmicos. A construção e manutenção destes *sub-clusters* é também uma área que pode ser explorada em investigação futura.

Com a implementação da metodologia CBR-DDE, a aprendizagem com o passado no apoio à negociação automática nos centros de controlo operacional pode ser muito em breve uma realidade nos CCO de várias companhias aéreas, como demonstra o protótipo MASDIMA. Acreditamos ainda que a metodologia CBR-DDE, agora apresentada, pode vir a ser introduzida noutros âmbitos onde a metodologia CBR ainda não tenha sido aplicada pela dificuldade de reutilização e adaptação de soluções.

¹sítio na Internet: <http://www.waset.org/conferences/2013/malaga/iccbr/>

Anexo A

MASDIMA

O sistema MASDIMA, *Multi-Agent System for Disruption Management*, é um protótipo desenvolvido no Laboratório de Inteligência Artificial e Ciência da Computação sobre o qual implementamos a aprendizagem com o passado, no apoio à negociação automática nos Centros de Controlo Operacional (CCO).

O MASDIMA está implementado em JAVA¹ e sobre a *framework* JADE (Bellifemine et al., 2001), que facilita a criação de sistemas multiagente. Foi utilizada a *NASA Worldwind API*² para a visualização dos dados de voo.

Uma descrição detalhada da interface pode ser encontrada em Castro (2013). Na figura A.1 pode ser consultada a aparência da interface principal para os utilizadores do sistema.

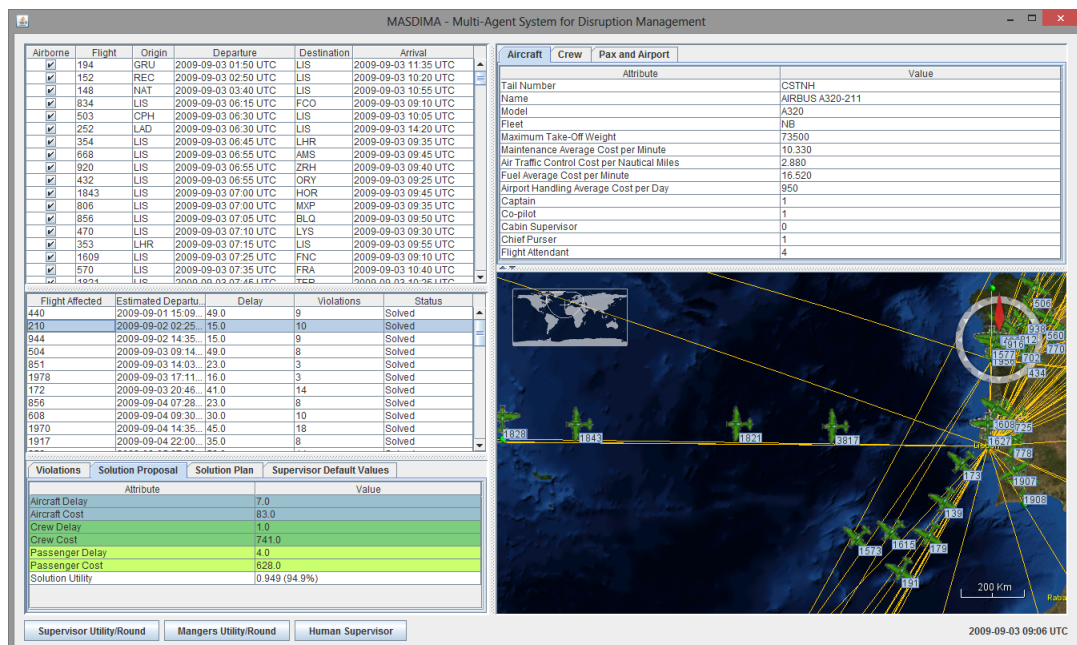


Figura A.1: Interface do sistema MASDIMA

¹<http://www.java.com>

²<http://worldwind.arc.nasa.gov/java/>

MASDIMA

Durante esta dissertação a interface do sistema MASDIMA não foi alterada.

Anexo B

Métricas

Neste anexo apresentamos as métricas usadas durante as experiências realizadas. Para cada métrica indicamos a sua identificação, definição, processo de cálculo e interpretação. Com esta informação, o leitor estará mais preparado para melhor compreender os resultados apresentados na secção 5.2.

São apresentadas métricas relacionadas com o transporte aéreo (secção B.1), o resultado da negociação (secção B.2) e desempenho do protocolo (secção B.3).

B.1 Transporte Aéreo

Definição B.1.1. *Tempo Médio de Atraso dos Voos*

Tempo médio de atraso à partida dos voos, em minutos, para uma experiência de n execuções e , dado por:

$$\overline{FD} = \frac{\sum_{e=1}^n \overline{FD}_e}{n} \quad (\text{B.1})$$

onde \overline{FD}_e é a média aritmética do atraso à partida (FD) de todos os voos incluídos na execução e . FD_i é dado por:

$$FD_i = etd_i - std_i \quad (\text{B.2})$$

onde etd_i é a hora de partida esperada e std_i a hora de partida originalmente escalonada para o voo i .

Interpretação: Quanto menor for o valor melhor, significando que a abordagem utilizada é capaz de minimizar os atrasos à partida dos voos (em média).

Definição B.1.2. *Tempo Médio de Atraso dos Tripulantes*

Tempo médio de atraso dos tripulantes, em minutos, para uma experiência de n execuções e , dado por:

$$\overline{CwD} = \frac{\sum_{e=1}^n \overline{CwD}_e}{n} \quad (\text{B.3})$$

Métricas

onde \overline{CwD}_e é a média aritmética do atraso dos tripulantes (CwD) de todos os voos incluídos na execução e . CwD_i é dado por:

$$CwD_i = esign_i - ssign_i \quad (B.4)$$

onde $esign_i$ é a hora de entrada ao serviço esperada e $ssign_i$ a entrada ao serviço originalmente escalonada para o voo i .

Interpretação: Quanto menor for o valor melhor, significando que a abordagem utilizada é capaz de minimizar os atrasos da apresentação ao serviço dos tripulantes (em média).

Definição B.1.3. Tempo Médio de Atraso da Viagem dos Passageiros

Tempo médio de atraso da viagem dos passageiros, em minutos, para uma experiência de n execuções e , dado por:

$$\overline{PD} = \frac{\sum_{e=1}^n \overline{PD}_e}{n} \quad (B.5)$$

onde \overline{PD}_e é a média aritmética do atraso da viagem (PD) para todos os passageiros de todos os voos incluídos na execução e . PD_i , para o passageiro i , é dado por:

$$PD_i = ett_i - stt_i \quad (B.6)$$

onde ett_i é o tempo de viagem esperado para o passageiro i , isto é, o tempo decorrido entre a partida do primeiro voo do passageiro até à hora de chegada esperada do último voo do seu itinerário e stt_i o tempo originalmente previsto no plano de operações para a mesma viagem para o passageiro i .

Interpretação: Quanto menor for o valor melhor, significando que a abordagem utilizada é capaz de minimizar os atrasos das viagens dos passageiros (em média).

Definição B.1.4. Custo Médio de Voo e Aeronave

Custo médio de voo e aeronave, em m.u., para uma experiência de n execuções e , dado por:

$$\overline{FC} = \frac{\sum_{e=1}^n \overline{FC}_e}{n} \quad (B.7)$$

onde \overline{FC}_e é a média aritmética dos custos com o voo e aeronave (FC) de todos os voos incluídos na execução e . FC para uma solução i de um problema (uma solução pode conter vários voos) é dada pela equação 7.3 em Castro (2013).

Interpretação: Quanto menor for o valor melhor, significando que a abordagem utilizada é capaz de minimizar os custos com voo e aeronaves (em média). As várias componentes para o cálculo dos custos podem ser consultadas na secção 7.5.1.1 em Castro (2013). É importante realçar que, por imposição da TAP Portugal, os custos apresentados não são os custos reais. Contudo permitem estabelecer comparações e por isso úteis para a nossa análise.

Definição B.1.5. Custo Médio com Tripulação

Custo médio da tripulação, em m.u., para uma experiência de n execuções e , dado por:

$$\overline{CC} = \frac{\sum_{e=1}^n \overline{CC}_e}{n} \quad (\text{B.8})$$

onde \overline{CC}_e é a média aritmética dos custos com tripulação (CC) de todos os voos incluídos na execução e . CC para uma solução i de um problema (uma solução pode conter vários voos) é dada pela equação 7.4 em Castro (2013).

Interpretação: Quanto menor for o valor melhor, significando que a abordagem utilizada é capaz de minimizar os custos com tripulação (em média). As várias componentes para o cálculo dos custos podem ser consultadas na secção 7.5.1.2 em Castro (2013).

Definição B.1.6. *Custo Médio com Passageiros*

Custo médio com passageiros, em m.u., para uma experiência de n execuções e , dado por:

$$\overline{PC} = \frac{\sum_{e=1}^n \overline{PC}_e}{n} \quad (\text{B.9})$$

onde \overline{PC}_e é a média aritmética dos custos com passageiros (PC) de todos os voos incluídos na execução e . PC para uma solução i de um problema (uma solução pode conter vários voos) é dada pela equação 7.5 em Castro (2013).

Interpretação: Quanto menor for o valor melhor, significando que a abordagem utilizada é capaz de minimizar os custos com passageiros (em média). As várias componentes para o cálculo dos custos podem ser consultadas na secção 7.5.1.3 em Castro (2013).

Definição B.1.7. *Rácio Médio de Recuperação dos Custos dos Voos*

A média do rácio de Recuperação dos Custos dos Voos para uma experiência de n execuções e , é dada por:

$$\overline{FCrcv} = \frac{\sum_{e=1}^n \overline{FCrcv}_e}{n} \quad (\text{B.10})$$

onde \overline{FCrcv}_e é a média aritmética do rácio de recuperação dos custos dos voos ($FCrcv$) de todos os voos incluídos na execução e . $FCrcv$ para um voo i é dado por:

$$FCrcv_i = \frac{FC_i}{OFC_i} \quad (\text{B.11})$$

onde FC_i é o custo, em m.u., de acordo com a equação 7.3 em Castro (2013), e OFC_i é o custo original do voo do problema a ser resolvido.

Interpretação: Este rácio relaciona os custos do voo encontrados pela abordagem utilizada para realizar as execuções e com os custos inicialmente previstos no problema utilizado na experiência. Quanto menor for o valor melhor. Um valor menor que um significa que a abordagem utilizada foi capaz de reduzir custos por comparação com a previsão original. Um valor igual a um significa que os custos se mantiveram inalterados ou, se superior a um, que aumentou os custos dos voos face aos custos originalmente previstos.

Definição B.1.8. *Rácio Médio de Recuperação dos Custos com Tripulação*

A média do rácio de Recuperação dos Custos com Tripulação para uma experiência de n execuções e , é dada por:

$$\overline{CCrcv} = \frac{\sum_{e=1}^n \overline{CCrcv_e}}{n} \quad (\text{B.12})$$

onde $\overline{CCrcv_e}$ é a média aritmética do rácio de recuperação dos custos com tripulação ($CCrcv$) de todos os voos incluídos na execução e . $CCrcv$ para um voo i é dado por:

$$CCrcv_i = \frac{CC_i}{OCC_i} \quad (\text{B.13})$$

onde CC_i é o custo, em m.u., de acordo com a equação 7.4 em Castro (2013), e OCC_i é o custo original da tripulação no problema a ser resolvido.

Interpretação: Este rácio relaciona os custos com a tripulação encontrados pela abordagem utilizada para realizar as execuções e com o custo com a tripulação inicialmente previsto no problema utilizado na experiência. Quanto menor for o valor melhor. Um valor menor que um significa que a abordagem utilizada foi capaz de reduzir custos por comparação com a previsão original. Um valor igual a um significa que os custos se mantiveram inalterados ou, se superior a um, que aumentou os custos dos voos face aos custos originalmente previstos.

Definição B.1.9. *Custo Médio de Voo por Minuto*

O custo médio de voo por minuto, em m.u. por minuto, para uma experiência de n execuções e , é dada por:

$$\overline{FCmin} = \frac{\sum_{e=1}^n \overline{FCmin_e}}{n} \quad (\text{B.14})$$

onde $\overline{FCmin_e}$ é o custo médio de voo por minuto ($FCmin$) de todos os voos incluídos na execução e e é dado por:

$$FCmin_e = \frac{FC_e}{OD_e} \quad (\text{B.15})$$

onde FC_e é a média aritmética dos custos com voo e aeronave (FC) de todos os voos incluídos na execução e . A definição de FC_i pode ser encontrada na definição B.1.4. OD_e é a média aritmética do atraso do voo do problema original a ser resolvido, incluído na execução e .

Interpretação: Quanto menor for este valor melhor, o que significa que a abordagem utilizada para realizar a execução e é capaz de produzir, em média, um melhor custo de voo e aeronave por minuto de atraso originalmente previsto. É útil para comparar a diferença entre abordagens porque o atraso originalmente previsto é igual para todas as abordagens.

Definição B.1.10. *Custo Médio com Tripulação por Minuto*

Métricas

O custo médio com tripulação por minuto, em m.u. por minuto, para uma experiência de n execuções e , é dada por:

$$\overline{CCmin} = \frac{\sum_{e=1}^n \overline{CCmin_e}}{n} \quad (B.16)$$

onde $\overline{CCmin_e}$ é o custo médio da tripulação por minuto ($CCmin$) de todos os voos incluídos na execução e e é dado por:

$$CCmin_e = \frac{CC_e}{OD_e} \quad (B.17)$$

onde CC_e é a média aritmética dos custos com tripulação (CC) de todos os voos incluídos na execução e . A definição de CC_i pode ser encontrada na definição B.1.5. OD_e é a média aritmética do atraso do voo do problema original a ser resolvido, incluído na execução e .

Interpretação: Quanto menor for este valor melhor, o que significa que a abordagem utilizada para realizar a execução e é capaz de produzir, em média, um melhor custo com tripulação por minuto de atraso originalmente previsto. É útil para comparar a diferença entre abordagens porque o atraso originalmente previsto é igual para todas as abordagens.

Definição B.1.11. *Custo Médio com Passageiros por Minuto*

O custo médio com passageiros por minuto, em m.u. por minuto, para uma experiência de n execuções e , é dada por:

$$\overline{PCmin} = \frac{\sum_{e=1}^n \overline{PCmin_e}}{n} \quad (B.18)$$

onde $\overline{PCmin_e}$ é o custo médio da tripulação por minuto ($PCmin$) de todos os voos incluídos na execução e e é dado por:

$$PCmin_e = \frac{PC_e}{OD_e} \quad (B.19)$$

onde PC_e é a média aritmética dos custos com passageiros (PC) de todos os voos incluídos na execução e . A definição de PC_i pode ser encontrada na definição B.1.6. OD_e é a média aritmética do atraso do voo do problema original a ser resolvido, incluído na execução e .

Interpretação: Quanto menor for este valor melhor, o que significa que a abordagem utilizada para realizar a execução e é capaz de produzir, em média, um custo com passageiros por minuto de atraso originalmente previsto. É útil para comparar a diferença entre abordagens porque o atraso originalmente previsto é igual para todas as abordagens.

Definição B.1.12. *Número Médio de Voos com atraso superior a 15 minutos*

O número médio de voos com atraso superior a 15 minutos, para uma experiência de n execuções e é dado por:

$$\overline{FD15min} = \frac{\sum_{e=1}^n \overline{FD15min_e}}{n} \quad (B.20)$$

onde $\overline{FD15min}_e$ é a média aritmética do número de voos com atrasos à partida superiores a 15 minutos ($FD15min$) incluídos na execução e .

Interpretação: Esta métrica fornece-nos o número médio de voos com atraso superior a 15 minutos. No ramo dos transportes aéreos a pontualidade é normalmente calculada para voos com atraso superior a 15 minutos. Quanto menor for este valor melhor, o que significa que a abordagem utilizada na execução e produz, em média, soluções com maior pontualidade.

Definição B.1.13. *Percentagem de Voos com atraso superior a 15 minutos*

A percentagem de voos com atraso superior a 15 minutos, para uma experiência de n execuções e é dado por:

$$p(\overline{FD15min}) = \frac{\sum_{e=1}^n \overline{FD15min}_e}{CP_e} \quad (B.21)$$

onde $\overline{FD15min}_n$ é o número médio de voos com atrasos à partida superiores a 15 minutos ($FD15min$), de acordo com a equação B.20 e CP_e é o número de eventos incluídos na execução e .

Interpretação: Esta métrica fornece-nos a pontualidade em percentagem e tem o mesmo objetivo da métrica $\overline{FD15min}$ definida em B.1.12

B.2 Desempenho Negocial

Definição B.2.1. *Utilidade Média Agente Supervisor*

A média da utilidade do agente supervisor, um valor no intervalo $[0, 1]$, para uma experiência de n execuções e , é dada por:

$$\overline{Usup} = \frac{\sum_{e=1}^n \overline{Usup}_e}{n} \quad (B.22)$$

onde \overline{Usup}_e é a média aritmética da utilidade da solução vencedora para o agente supervisor ($Usup$), para os problemas incluídos na execução e . $Usup_i$ para a solução vencedora i de um problema é dado pela equação 3.4.

Interpretação: O agente supervisor representa a integração de todos os objetivos do CCO, isto é, chegar a soluções que incluam as três dimensões do problema. Este agente tem uma visão global do problema. Quanto mais elevado for este valor melhor, o que significa que a abordagem utilizada para realizar a execução e está a produzir soluções que melhor correspondem aos interesses do agente.

Definição B.2.2. *Utilidade Média Agente Manager Avião*

A média da utilidade agente manager avião, um valor no intervalo $[0, 1]$, para uma experiência de n execuções e , é dada por:

$$\overline{Ua/c} = \frac{\sum_{e=1}^n \overline{Ua/c}_e}{n} \quad (B.23)$$

onde $\overline{Ua/c_e}$ é a média aritmética da utilidade da solução parcial da dimensão avião, incluída na solução vencedora, para o agente manager avião (Ua/c), para os problemas incluídos na execução e . Ua/c_i para a solução parcial i , da dimensão avião, de um problema é dado pela equação 3.1.

Interpretação: O agente manager avião representa a dimensão do voo e aeronave no CCO. Este agente tem uma visão local do problema, possui os seus próprios objetivos (diferentes do agente supervisor). Quanto mais elevado for o valor melhor para este agente. Contudo, uma utilidade mais baixa não corresponde a uma solução de qualidade inferior no seu global.

Definição B.2.3. *Utilidade Média Agente Manager Tripulação*

A média da utilidade agente manager tripulação, um valor no intervalo $[0, 1]$, para uma experiência de n execuções e , é dada por:

$$\overline{Ucrew} = \frac{\sum_{e=1}^n \overline{Ucrew_e}}{n} \quad (B.24)$$

onde $\overline{Ucrew_e}$ é a média aritmética da utilidade da solução parcial da dimensão tripulação, incluída na solução vencedora, para o agente manager tripulação ($Ucrew$), para os problemas incluídos na execução e . $Ucrew_i$ para a solução parcial i , da dimensão tripulação, de um problema é dado pela equação 3.2.

Interpretação: O agente manager tripulação representa a dimensão da tripulação no CCO. Este agente tem uma visão local do problema, possui os seus próprios objetivos (diferentes do agente supervisor). Quanto mais elevado for o valor melhor para este agente. Contudo, uma utilidade mais baixa não corresponde a uma solução de qualidade inferior no seu global.

Definição B.2.4. *Utilidade Média Agente Manager Passageiros*

A média da utilidade agente manager passageiros, um valor no intervalo $[0, 1]$, para uma experiência de n execuções e , é dada por:

$$\overline{Upax} = \frac{\sum_{e=1}^n \overline{Upax_e}}{n} \quad (B.25)$$

onde $\overline{Upax_e}$ é a média aritmética da utilidade da solução parcial da dimensão passageiros, incluída na solução vencedora, para o agente manager tripulação ($Upax$), para os problemas incluídos na execução e . $Upax_i$ para a solução parcial i , da dimensão passageiros, de um problema é dado pela equação 3.3.

Interpretação: O agente manager passageiros representa a dimensão da tripulação no AOCC. Este agente tem uma visão local do problema, possui os seus próprios objetivos (diferentes do agente supervisor). Quanto mais elevado for o valor melhor para este agente. Contudo, uma utilidade mais baixa não corresponde a uma solução de qualidade inferior no seu global.

Definição B.2.5. *Utilidade Média de Bem-estar Social*

A utilidade média de bem-estar social da solução vencedora da negociação, para uma experiência de n execuções e , é dada por:

$$\overline{Usw} = \overline{Ua/c_n} + \overline{Ucrew_n} + \overline{Upax_n} \quad (B.26)$$

onde $\overline{Ua/c_n}$ é a média da utilidade do agente manager avião, de acordo com a equação B.23, $\overline{Ucrew_n}$ é a média da utilidade do agente manager tripulação, de acordo com a equação B.24 e $\overline{Upax_n}$ é a média da utilidade do agente manager passageiros, de acordo com a equação B.25.

Interpretação: Esta métrica avalia a utilidade de bem-estar social que, segundo Sandholm (1999), é o bem-estar global que corresponde à soma das utilidades individuais de todos os agentes. Utilizamos esta métrica para comparar a utilidade global percebida pelos agentes manager (avião, tripulação e passageiros). Quanto mais elevado, especialmente se conjugados com valores elevados de \overline{Usup} , melhor.

Definição B.2.6. Δ Médio para a Solução Ótima do Domínio

O Δ médio para a solução ótima do domínio, um valor no intervalo $[0, 1]$, para uma experiência de n execuções e , é dado por:

$$\overline{\Delta(optimal)} = \frac{\sum_{e=1}^n \overline{\Delta(optimal)}_e}{n} \quad (B.27)$$

onde $\overline{\Delta(optimal)}$ é a média aritmética do Δ à solução ótima do domínio ($\overline{\Delta(optimal)}$) para todos os problemas incluídos na execução e . $\overline{\Delta(optimal)}$, para um dado problema i é:

$$\overline{\Delta(optimal)}_i = Uopt_i - Usup_i \quad (B.28)$$

onde $Uopt_i$ é a utilidade, para o agente supervisor, do plano original para o problema i , isto é, antes de ter ocorrido uma rotura, e $Usup_i$ é a utilidade do agente supervisor para a solução encontrada para o problema i , de acordo com a equação B.22.

Interpretação: Quanto menor for este valor melhor, o que significa que a abordagem utilizada na execução e é capaz de produzir soluções que são próximas do plano original, em termos de utilidade para o agente supervisor. É importante referir que não estamos a afirmar que as soluções produzidas pelo nosso sistema são soluções ótimas do ponto de vista matemático.

Definição B.2.7. *Equidade Global*

A justiça global das soluções que ganharam as negociações para uma experiência de n execuções e , é dada pela variância das utilidades médias dos agentes que representam cada uma das dimensões do problema:

$$GF = var(\overline{Ua/c_n}; \overline{Ucrew_n}; \overline{Upax_n};) \quad (B.29)$$

onde $\overline{Ua/c_n}$ é a média da utilidade do agente manager avião, de acordo com a equação B.23, $\overline{Ucrew_n}$ é a média da utilidade do agente manager tripulação, de acordo com a equação B.24 e $\overline{Upax_n}$ é a média da utilidade do agente manager passageiros, de acordo com a equação B.25.

Interpretação: O objetivo desta métrica é o de medir o equilíbrio através da variância das utilidades dos agentes. Quanto mais perto de zero estiver o valor melhor.

B.3 Desempenho do Protocolo

Definição B.3.1. *Número Médio de Rondas até atingir Acordo*

O número médio de rondas até que se atinja acordo na negociação, para uma experiência de n execuções e , é dado por:

$$\overline{NR} = \frac{\sum_{e=1}^n \overline{NR}_e}{n} \quad (\text{B.30})$$

onde \overline{NR}_e a média aritmética do número de rondas necessário para que se atinja um acordo (\overline{NR}) de todos os problemas incluídos na execução e .

Interpretação: Quanto menor for o valor melhor, indicando que a abordagem utilizada na execução e é capaz de atingir um acordo em menos rondas de negociação.

Definição B.3.2. *Tempo Médio de Negociação*

O tempo médio de negociação, para uma experiência de n execuções e , é dado por:

$$\overline{NT} = \frac{\sum_{e=1}^n \overline{NT}_e}{n} \quad (\text{B.31})$$

onde \overline{NT}_e a média aritmética do tempo de negociação (\overline{NT}) de todos os problemas incluídos na execução e . O tempo de negociação NT_i para um problema i é o tempo decorrido entre o primeiro *call-for-proposal*, emitido pelo agente supervisor, e a comunicação ao vencedor da negociação, também pelo agente supervisor.

Interpretação: Quanto menor for o valor melhor. Contudo, este valor é altamente dependente do computador e distribuição física do sistema multiagente bem como dos algoritmos utilizados para encontrar as soluções candidatas para os problemas.

Definição B.3.3. *Tempo Médio de Pesquisa*

O tempo médio de pesquisa, para uma experiência de n execuções e , é dado por:

$$\overline{ST} = \frac{\sum_{e=1}^n \overline{ST}_e}{n} \quad (\text{B.32})$$

onde \overline{ST}_e a média aritmética do tempo de pesquisa (\overline{ST}) de todos os problemas incluídos na execução e . O tempo de pesquisa ST_i para um problema i é o tempo decorrido entre o primeiro *call-for-proposal*, emitido pelos agentes manager de cada uma das dimensões para os seus especialistas, até o momento em que os managers tem as soluções prontas a enviar ao agente supervisor.

Interpretação: Quanto menor for o valor melhor. Contudo, este valor contem as mesmas dependências que a métrica *Tempo Médio de Negociação* (definição B.3.2).

Definição B.3.4. *Número Médio de Mensagens Trocadas*

O número médio de mensagens trocadas, para uma experiência de n execuções e , é dado por:

$$\overline{Msg} = \frac{\sum_{e=1}^n \overline{Msg}_e}{n} \quad (\text{B.33})$$

onde Msg_e é o número de mensagens trocadas entre todos os agentes (Msg) durante a negociação para todos os problemas incluídos na execução e .

Interpretação: Quanto menor for o valor melhor, o que significa que os agentes foram capaz de chegar a um acordo trocando menos mensagens entre si.

Definição B.3.5. *Número Médio de Mensagens por Problema*

O número médio de mensagens trocadas por problema, para uma experiência de n execuções e , é dado por:

$$\overline{Mprb} = \frac{\sum_{e=1}^n Mprb_e}{n} \quad (B.34)$$

onde $Mprb_e$ é o número de mensagens trocadas por problema ($Mprb$) durante a negociação para todos os problemas incluídos na execução e , e é dado por:

$$Mprb_e = \frac{Msg_e}{CP_e} \quad (B.35)$$

onde Msg_e é o número de mensagens trocadas por todos os agentes durante a negociação de todos os problemas incluídos na execução e , e CP_e é o numero de problemas incluídos na execução e .

Interpretação: Quanto menor for o valor melhor, o que significa que os agentes foram capazes de chegar a um acordo trocando menos mensagens entre si para resolver um problema.

Anexo C

Ficheiro configuração Módulo CBR

Neste anexo apresentamos o conteúdo do ficheiro XML de configuração do módulo de aprendizagem com o passado no sistema MASDIMA. Estas informações são lidas uma única vez no início da execução do sistema.

O ficheiro é composto por um nó raiz denominado *cbr* que no seu interior contém os nós *mode* e *events*, respetivamente. O *mode* tem como atributos *value*, onde se especifica a abordagem (das especificadas na secção 5.1.2) que o sistema deve utilizar e, caso a abordagem escolhida utilize um fator de penalização, deve ser incluído o atributo *penalization* com um valor entre real entre 0 e 1. O nó *events* tem no seu interior um conjunto de nós *event* que representam as causas de eventos possíveis e os respetivos parâmetros e pesos a utilizar na função de similitude (definida na secção 4.1.2).

```
<?xml version="1.0" encoding="UTF-8"?>
<cbr most-similar="3" >
  <mode value="3" penalization="0.5" />
  <events>
    <event type="airp" table="cbr_event_airp">
      <parameter name="origin" weight="0.4" type="text"/>
      <parameter name="flight_number" weight="0.3" type="text" />
      <parameter name="scheduled_time_of_departure" weight="0.2"
        type="time" mode="continuous" measure="minute" lambda="0.5"
        />
      <parameter name="resource_type" weight="0.1" type="text"/>
    </event>
    <event type="atc" table="cbr_event_atc">
      <parameter name="destination" weight="0.4" type="text"/>
      <parameter name="origin" weight="0.3" type="text" />
      <parameter name="scheduled_time_of_arrival" weight="0.2" type
        ="time" mode="continuous" measure="minute" lambda="0.5" />
      <parameter name="flight_number" weight="0.1" type="text"/>
    </event>
  </events>
</cbr>
```

Ficheiro configuração Módulo CBR

```
</event>
<event type="comm" table="cbr_event_comm">
  <parameter name="flight_number" weight="0.4" type="text"/>
  <parameter name="scheduled_time_of_departure" weight="0.3"
    type="time" mode="continuous" measure="minute" lambda="0.5"
    " />
  <parameter name="origin" weight="0.2" type="text"/>
  <parameter name="destination" weight="0.1" type="text" />
</event>
<event type="crot" table="cbr_event_crot">
  <parameter name="destination" weight="0.4" type="text"/>
  <parameter name="origin" weight="0.3" type="text" />
  <parameter name="flight_number" weight="0.2" type="text" />
  <parameter name="resource_type" weight="0.1" type="text" />
</event>
<event type="hand" table="cbr_event_hand">
  <parameter name="origin" weight="0.4" type="text" />
  <parameter name="flight_number" weight="0.3" type="text"/>
  <parameter name="scheduled_time_of_departure" weight="0.2"
    type="time" mode="continuous" measure="minute" lambda="0.5"
    " />
  <parameter name="resource_type" weight="0.1" type="text" />
</event>
<event type="induty" table="cbr_event_induty">
  <parameter name="crew_res_type" weight="0.4" type="text"/>
  <parameter name="flight_number" weight="0.3" type="text"/>
  <parameter name="scheduled_time_of_departure" weight="0.2"
    type="time" mode="continuous" measure="minute" lambda="0.5"
    " />
  <parameter name="resource_type" weight="0.1" type="text" />
</event>
<event type="maint" table="cbr_event_maint">
  <parameter name="resource_affected" weight="0.4" type="text"/>
  <parameter name="resource_type" weight="0.3" type="text" />
  <parameter name="resource_cap" weight="0.2" type="text" />
  <parameter name="origin" weight="0.1" type="text" />
</event>
<event type="meteo" table="cbr_event_meteo">
  <parameter name="origin" weight="0.4" type="text" />
```

Ficheiro configuração Módulo CBR

```
<parameter name="scheduled_time_of_departure" weight="0.3"
  type="time" mode="continuous" measure="minute" lambda="0.5
  " />
<parameter name="scheduled_time_of_departure" weight="0.2"
  type="time" mode="periodic" measure="month" lambda="0.5" /
>
<parameter name="resource_type" weight="0.1" type="text" />
</event>
<event type="rot" table="cbr_event_rot">
  <parameter name="flight_number" weight="0.4" type="text"/>
  <parameter name="origin" weight="0.3" type="text" />
  <parameter name="resource_type" weight="0.2" type="text" />
  <parameter name="destination" weight="0.1" type="text"/>
</event>
<event type="rules" table="cbr_event_rules">
  <parameter name="flight_number" weight="0.4" type="text"/>
  <parameter name="scheduled_time_of_departure" weight="0.3"
    type="time" mode="continuous" measure="minute" lambda="0.5
    " />
  <parameter name="origin" weight="0.2" type="text" />
  <parameter name="destination" weight="0.1" type="text"/>
</event>
<event type="sec" table="cbr_event_sec">
  <parameter name="resource_affected" weight="0.4" type="text"
  />
  <parameter name="resource_type" weight="0.3" type="text" />
  <parameter name="origin" weight="0.2" type="text" />
  <parameter name="destination" weight="0.1" type="text" />
</event>
<event type="sign" table="cbr_event_sign">
  <parameter name="flight_number" weight="0.4" type="text"/>
  <parameter name="scheduled_time_of_departure" weight="0.3"
    type="time" mode="continuous" measure="minute" lambda="0.5
    " />
  <parameter name="origin" weight="0.2" type="text" />
  <parameter name="destination" weight="0.1" type="text" />
</event>
<event type="other" table="cbr_event_other">
  <parameter name="flight_number" weight="0.125" type="text"/>
```

Ficheiro configuração Módulo CBR

```
<parameter name="scheduled_time_of_departure" weight="0.125"
  type="time" mode="continuous" measure="minute" lambda="0.5
" />
<parameter name="origin" weight="0.125" type="text" />
<parameter name="destination" weight="0.125" type="text" />
<parameter name="resource_type" weight="0.125" type="text" />
<parameter name="resource_affected" weight="0.125" type="text
" />
<parameter name="crew_res_type" weight="0.125" type="text" />
<parameter name="scheduled_time_of_arrival" weight="0.125"
  type="time" mode="continuous" measure="minute" lambda="0.5
" />
</event>
</events>
</cbr>
```


Referências

- Aamodt, A. e E. Plaza (1994). Case-based reasoning; foundational issues, methodological variations, and system approaches. *AI COMMUNICATIONS* 7(1), 39–59.
- Acorn, T. L. e S. H. Walden (1992). Smart: Support management automated reasoning technology for compaq customer service. Em *Proceedings of the fourth conference on Innovative applications of artificial intelligence*, pp. 3–18. AAAI Press.
- Bartlett, F. C. (1932). *Remembering. A study in experimental and social psychology*. Cambridge: Cambridge University Press.
- Bellifemine, F., A. Poggi, e G. Rimassa (2001). Developing multi-agent systems with jade. Em *Intelligent Agents VII Agent Theories Architectures and Languages*, pp. 89–103. Springer.
- Bergmann, R., J. Kolodner, e E. Plaza (2005, Setembro). Representation in case-based reasoning. *Knowl. Eng. Rev.* 20(3), 209–213.
- Bergmann, R. e W. Wilke (1996). On the role of abstraction in case-based reasoning. Em *Proceedings of the Third European Workshop on Advances in Case-Based Reasoning*, EWCBR '96, London, UK, UK, pp. 28–43. Springer-Verlag.
- Beyhoff, S. (1995). Code-sharing: a summary of the german study. *Journal of Air Transport Management* 2(2), 127 – 129.
- Bradley P. Allen (1994). Case-based reasoning: business applications. *Communications of the ACM* 37(3), 40–42.
- Castro, A. (2008). Centros de controlo operacional: organização e ferramentas. Instituto Superior de Educação e Ciências.
- Castro, A., A. Rocha, e E. Oliveira (2012). Towards an autonomous and intelligent airline operations control. Em *Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference on*, pp. 1429–1434. IEEE.
- Castro, A. J. M. (2013, July). *A Distributed Approach to Integrated and Dynamic Disruption Management in Airline Operations Control*. Phd thesis, Faculty of Engineering, University of Porto, Porto, Portugal.
- Castro, A. J. M. e E. Oliveira (2011, March). A new concept for disruption management in airline operations control. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering* 3(3), 269–290.
- Chow, H. K., K. L. Choy, W. Lee, e K. Lau (2006). Design of a {RFID} case-based resource management system for warehouse operations. *Expert Systems with Applications* 30(4), 561 – 576.

REFERÊNCIAS

- CODA Digest (2012). Delay to air transport in europe. Technical report, EUROCONTROL.
- Díaz-Agudo, B. e P. A. González-Calero (2001). A declarative similarity framework for knowledge intensive cbr. Em D. W. Aha e I. Watson (Eds.), *ICCBR*, Volume 2080 of *Lecture Notes in Computer Science*, pp. 158–172. Springer.
- De Mantaras, R. L., D. Mcsherry, D. Bridge, D. Leake, B. Smyth, S. Craw, B. Faltings, M. L. Maher, M. T. Cox, K. Forbus, M. Keane, A. Aamodt, e I. Watson (2005). Retrieval, reuse, revision and retention in case-based reasoning. *Knowl. Eng. Rev.* 20(3), 215–240.
- Goel, A. J. e J. L. Kolodner (1991). Towards a case-based tool for aiding conceptual design problem solving. *DARPA Case-Based Reasoning Workshop*, 109–20.
- Hammond, K. J. (1990). Explaining and repairing plans that fail. *Artificial intelligence* 45(1), 173–228.
- Keller, J., M. Gray, e J. Givens (1985). A fuzzy k-nearest neighbor algorithm. *Systems, Man and Cybernetics, IEEE Transactions on* nd(4), 580–585.
- Kitano, H., A. Shibata, H. Shimazu, J. Kajihara, e A. Sato (1992). Building large-scale and corporate-wide case-based systems: Integration of the organizational and machine executable algorithms. Em *Proceedings of the National Conference on Artificial Intelligence*, pp. 843–843. JOHN WILEY & SONS LTD.
- Kohl, N., A. Larsen, J. Larsen, A. Ross, e S. Tiourine (2007). Airline disruption management—perspectives, experiences and outlook. *Journal of Air Transport Management* 13(3), 149–162.
- Kolodner, J. (1983a). Reconstructive memory: A computer model. *Cognitive Science* 7, 281–328.
- Kolodner, J. (1993). Case-based reasoning (morgan kaufmann). *San Mateo, CA*, 545–555.
- Kolodner, J. L. (1983b). Maintaining organization in a dynamic long-term memory. *Cognitive Science* 7(4), 243 – 280.
- Kolodner, J. L. (1991, Abril). Improving human decision making through case-based decision aiding. *AI Mag.* 12(2), 52–68.
- Kruusmaa, M. (2003). Global navigation in dynamic environments using case-based reasoning. *Autonomous Robots* 14(1), 71–91.
- Lenz, M. e H.-D. Burkhard (1996). Case retrieval nets: Basic ideas and extensions. Em *Proceedings of the 20th Annual German Conference on Artificial Intelligence: Advances in Artificial Intelligence*, KI '96, London, UK, UK, pp. 227–239. Springer-Verlag.
- Park, Y.-J., B.-C. Kim, e S.-H. Chun (2006). New knowledge extraction technique using probability for case-based reasoning: application to medical diagnosis. *Expert Systems* 23(1), 2–20.
- Plaza, E. (1995). Cases as terms: A feature term approach to the structured representation of cases. Em M. M. Veloso e A. Aamodt (Eds.), *ICCBR*, Volume 1010 of *Lecture Notes in Computer Science*, pp. 265–276. Springer.
- Richter, M. M. (2003). Knowledge containers. Em I. Watson (Ed.), *Readings in Case-Based Reasoning*. Morgan Kaufmann Publishers.

REFERÊNCIAS

- Richter, M. M. e A. Aamodt (2005, Setembro). Case-based reasoning foundations. *Knowl. Eng. Rev.* 20(3), 203–207.
- Sandholm, T. W. (1999). Distributed rational decision making. *Multiagent systems: A modern approach to distributed artificial intelligence*, 201–258.
- Schank, R. C. (1983). *Dynamic Memory: A Theory of Reminding and Learning in Computers and People*. New York, NY, USA: Cambridge University Press.
- Smyth, B. e M. T. Keane (1998). Adaptation-guided retrieval: questioning the similarity assumption in reasoning. *Artificial Intelligence* 102(2), 249–293.
- Stanfill, C. e D. Waltz (1986, Dezembro). Toward memory-based reasoning. *Communications of the ACM* 29(12), 1213–1228.
- Teixeira, F., A. J. M. Castro, A. P. Rocha, e E. Oliveira (2013, 9-12 September). Multi-agent learning in both cooperative and competitive environments. Em *To appear in Proceedings of the XVI Portuguese Conference on Artificial Intelligence*, Angra do Heroísmo, Azores, Portugal.
- Urdiales, C., E. Perez, J. Vázquez-Salceda, M. Sánchez-Marrè, e F. Sandoval (2006). A purely reactive navigation scheme for dynamic environments using case-based reasoning. *Autonomous Robots* 21(1), 65–78.
- Veloso, M. M. e J. G. Carbonell (1994). Case-based reasoning in prodigy. Em R. S. Michalski e G. Teccuci (Eds.), *Machine Learning: A Multistrategy Approach, Volume IV*, pp. 523–548. Morgan Kaufmann.
- Watson, I. (1999). Case-based reasoning is a methodology not a technology. *Knowledge-Based Systems* 12(5–6), 303 – 308.
- Wess, S., K. Althoff, e G. Derwand (1994). Using k-d trees to improve the retrieval step in case-based reasoning. *Topics in Case-Based Reasoning* nd, 167–181.
- Wooldridge, M. e P. Ciancarini (2001). Agent-oriented software engineering: the state of the art. *Lecture notes in computer science* nd, 1–28.
- Zito-Wolf, R. J. (1993). *Case-based representations for procedural knowledge*. Ph. D. thesis, Waltham, MA, USA. AAI9322366.